

Ahryman Seixas Busse de Siqueira Nascimento

**DESENVOLVIMENTO DE FERRAMENTAS BASEADAS EM  
REDES NEURAIIS PARA INFERÊNCIAS E PROGNÓSTICOS  
EM ENSAIOS DE DESEMPENHO DE COMPRESSORES  
HERMÉTICOS**

Dissertação submetida ao Programa de  
Pós-Graduação em Engenharia  
Mecânica da Universidade Federal de  
Santa Catarina para a obtenção do Grau  
de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Carlos Alberto  
Flesch.

Coorientador: Dr. Cesar Alberto Penz.

Florianópolis  
2015

**Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.**

Nascimento, Ahryman

Desenvolvimento de ferramentas baseadas em redes neurais para inferências e prognósticos em ensaios de desempenho de compressores herméticos / Ahryman Nascimento ; orientador, Carlos Alberto Flesch ; coorientador, Cesar Alberto Penz. - Florianópolis, SC, 2015.

128 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Mecânica.

Inclui referências

1. Engenharia Mecânica. 2. Ensaios de desempenho energético. 3. Compressores. 4. Redes neurais. I. Flesch, Carlos Alberto. II. Penz, Cesar Alberto. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Mecânica. IV. Título.

Ahryman Seixas Busse de Siqueira Nascimento

**DESENVOLVIMENTO DE FERRAMENTAS BASEADAS EM  
REDES NEURAIIS PARA INFERÊNCIAS E PROGNÓSTICOS  
EM ENSAIOS DE DESEMPENHO DE COMPRESSORES  
HERMÉTICOS**

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Engenharia Mecânica”, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Mecânica.

Florianópolis, 26 de agosto de 2015.

Prof. Armando Albertazzi Gonçalves Jr., Dr. Eng.  
Coordenador do Programa de Pós-Graduação em Engenharia Mecânica

Prof. Carlos Alberto Flesch, Dr. Eng.  
Orientador

Cesar Alberto Penz, Dr. Eng.  
Coorientador

**Banca Examinadora:**

Prof. Carlos Alberto Flesch, Dr. Eng. (Presidente)  
Universidade Federal de Santa Catarina

Prof. Tiago Loureiro Figaro da Costa Pinto, Dr. Eng.  
Universidade Federal de Santa Catarina

Prof. Mauro Roisenberg, Dr. Eng.  
Universidade Federal de Santa Catarina

Prof. Marco Aurélio de Oliveira, Dr. Eng.  
Sociedade Educacional de Santa Catarina



## **AGRADECIMENTOS**

Aos meus pais, Carlos Eduardo e Eunice, pelo apoio e incentivo ao longo de toda a minha jornada acadêmica.

Ao professor Carlos Alberto Flesch e ao Dr. Cesar Alberto Penz, pela orientação e encorajamento durante todas as etapas deste trabalho.

À equipe do Laboratório de Metrologia e Automação da Universidade Federal de Santa Catarina, pelo espaço e recursos cedidos durante o trabalho realizado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos durante o mestrado.



*Em memória de Ahryman e Leda.  
Simplesmente, Obrigado!*





## RESUMO

Dentre os diversos testes realizados em compressores herméticos durante as fases de desenvolvimento e produção, destacam-se os ensaios de desempenho energético. Os principais parâmetros de desempenho obtidos através desse ensaio são: capacidade de refrigeração, potência elétrica consumida e coeficiente de performance. Os ensaios duram, em média, 4 horas, sendo as 3 primeiras horas em regime transitório e a última hora em regime permanente – caracterizado por um conjunto de variáveis que permanecem dentro de limites de variação predefinidos por norma – durante o qual são realizadas medições para obtenção do valor final dos parâmetros de desempenho. Devido ao elevado tempo necessário para a realização do ensaio, o mesmo acaba por se tornar um gargalo no processo de controle de qualidade. Trabalhos anteriores mostraram a viabilidade da aplicação de redes neurais artificiais como forma de redução de tempo de ensaio. Tais ferramentas analisam o comportamento dos parâmetros de desempenho durante o período transiente e inferem o momento em que ocorre a transição para o regime permanente. A partir da inferência, é realizado um prognóstico do valor final dos parâmetros. Como características comuns em todos os trabalhos anteriores, tem-se: pequeno número de ensaios analisados e aplicação de um método específico para medição da capacidade de refrigeração. Neste trabalho foi dada continuidade aos estudos, ampliando o universo de análise para mais de mil ensaios, abordando os três parâmetros de desempenho energético e estudando a aplicação de um método alternativo para medição da capacidade. A análise dos resultados revelou uma redução de mais de 50% do tempo de ensaio através da utilização das ferramentas. As mesmas foram capazes de obter inferência para mais de 98% dos ensaios avaliados e apresentaram uma diferença média percentual entre os prognósticos e o valor final do ensaio tradicional dentro de uma faixa de  $\pm 2\%$ , para um nível de confiança de 95%.

**Palavras-chave:** Ensaios de desempenho energético de compressores. Compressores de refrigeração. Redes neurais.



## ABSTRACT

Among the tests of which hermetic compressors are subjected to during the production and development phases, the performance test stands out due to its reliability and international acceptance. The main performance parameters obtained by the test are the refrigerating capacity, the consumed power and the coefficient of performance. The test takes, on average, four hours, of which the initial three are on transitory regime and the last one in permanent regime, where the measurements to obtain the performance parameters are taken. Due to the high amount of time required for these tests, its application ends up causing a delay in the quality control process. Previous works have shown the viability of using neural networks tools as a way to reduce the test time. These tools analyze the behavior of the performance parameters during the transient period and infer the moment it reaches the steady state condition. By using the data collected just before the inference, they return a prognostic of the final value of the parameter. All previous works had in common a small number of data test and the use of a specific method for measuring the refrigerating capacity. In this work, this study has been continued, with the use of more than a thousand performance tests to train, and test, the tools. The three performance parameters were considered and a different method of measuring the refrigerating capacity was used. The reduction of time registered was of more than 50% for all performance parameters, when compared to the traditional test. The tools were able to obtain inference for more than 98% of the test set. The average difference between the prognostics and the final values of the parameters tested was within a margin of  $\pm 2\%$  for a level of confidence of 95%.

**Keywords:** Performance test. Compressors. Neural Network.



## LISTA DE FIGURAS

Figura 1 - Ciclo de refrigeração por compressão de vapor .....	31
Figura 2 - Diagrama pressão x entalpia do ciclo ideal de refrigeração por compressão de vapor.....	32
Figura 3 - Ciclo ideal de refrigeração por compressão de vapor com etapas adicionais .....	33
Figura 4 - Calorímetro de fluido secundário .....	35
Figura 5 - Circuito para o método F.....	37
Figura 6 - Dinâmica da capacidade para diferentes métodos de medição.....	38
Figura 7 - Circuito da bancada de desempenho desenvolvida em trabalhos anteriores .....	40
Figura 8 - Modelo de neurônio .....	45
Figura 9 - Comportamento da função de ativação limiar .....	46
Figura 10 - Comportamento de funções sigmóides.....	46
Figura 11 - Exemplo de rede <i>feedforward</i> multicamada .....	48
Figura 12 - Fluxo de sinal para cálculo da atualização de peso em um neurônio da camada de saída .....	51
Figura 13 - Representação do dilema bias/variância.....	54
Figura 14 - Método de parada antecipada através de validação cruzada.....	55
Figura 15 - Representação de arquitetura de rede neural com linhas de atraso..	58
Figura 16 - Sistema neural desenvolvido por Lima (2010b).....	59
Figura 17 - Transição do regime transitório para o permanente em ensaio da capacidade de refrigeração.....	61
Figura 18 - Esquema geral da ferramenta para inferência do regime permanente dos parâmetros de desempenho .....	62
Figura 19 - Representação das entradas relacionadas ao parâmetro de desempenho .....	65
Figura 20 - Capacidade de refrigeração antes e após equalização .....	66
Figura 21 - Efeito das funções de normalização em uma entrada da rede neural .....	67
Figura 22 - Intervalo de ensaio utilizado para o treinamento.....	68
Figura 23 - Exemplo de saída da rede neural em relação a um ensaio de capacidade de refrigeração.....	69
Figura 24 - Saída da rede neural para um ensaio de capacidade de refrigeração com estabilização momentânea.....	70
Figura 25 - Esquema geral da ferramenta para o prognóstico do valor final dos parâmetros de desempenho .....	71
Figura 26 - Intervalo de ensaio utilizado para o treinamento da rede de prognóstico .....	74
Figura 27 - Ensaio com anomalia no sinal de capacidade de refrigeração.....	75
Figura 28 - Dinâmicas da capacidade de refrigeração obtida pelo método A....	76
Figura 29 - Obtenção do conjunto de ensaios para treinamento e validação das redes neurais .....	78

Figura 30 - Comportamento do comitê de redes de inferência da capacidade de refrigeração para diferentes patamares de decisão.....	80
Figura 31 - Comportamento das redes de inferência de entrada em regime permanente da capacidade de refrigeração com o patamar de decisão de 0,7 ...	81
Figura 32 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração ....	82
Figura 33 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração	82
Figura 34 - Comportamento do comitê de redes de inferência do consumo para diferentes patamares de decisão.....	83
Figura 35 - Comportamento do comitê de inferência de entrada em regime permanente do consumo com o patamar de decisão de 0,7 .....	84
Figura 36 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente do consumo .....	85
Figura 37 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente do consumo .....	85
Figura 38 - Comportamento do comitê de redes de inferência do COP para diferentes patamares de decisão.....	86
Figura 39 - Comportamento do comitê de inferência de entrada em regime permanente do COP com o patamar de decisão de 0,7 .....	87
Figura 40 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente do COP.....	88
Figura 41 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente do COP .....	88
Figura 42 - Diferença média percentual para diversos limiares no comitê de inferência da capacidade.....	89
Figura 43 - Comportamento do comitê de redes de inferência da capacidade de refrigeração para diferentes limiares.....	90
Figura 44 - Diferença média percentual versus tempo de espera para o limiar 30 .....	91
Figura 45 - Tempo de espera para os diversos limiares no comitê de inferência da capacidade .....	92
Figura 46 - Diferença média percentual para diversos limiares no comitê de inferência do consumo.....	94
Figura 47 - Tempo de espera para os diversos limiares no comitê de inferência do consumo.....	94
Figura 48 - Diferença média percentual para diversos limiares no comitê de inferência do COP .....	96
Figura 49 - Tempo de espera para os diversos limiares no comitê de inferência do COP .....	96
Figura 50 - Histograma das diferenças entre prognóstico e valor final da capacidade de refrigeração .....	99
Figura 51 - Histograma das diferenças entre prognóstico e valor final do consumo .....	100

Figura 52 - Histograma das diferenças entre prognóstico e valor final do COP .....	101
Figura 53 - Ensaio com a maior diferença entre prognóstico e valor final de ensaio para a capacidade de refrigeração .....	104
Figura 54 - Ensaio com a maior diferença entre prognóstico e valor final para o consumo.....	107
Figura 55 - Ensaio com a segunda maior diferença entre prognóstico e valor final para o COP .....	110
Figura 56 - Ensaio de capacidade com estabilização lenta e erro de falso positivo .....	116
Figura 57 - Ensaio de consumo com estabilização momentânea .....	117
Figura 58 - Representação gráfica da adição de uma possível nona entrada à rede de prognóstico.....	118





## LISTA DE QUADROS

Quadro 1 - Arquitetura da rede neural para inferência do regime permanente ..	62
Quadro 2 - Valores arbitrados para os critérios de parada da rede de inferência .....	63
Quadro 3 - Entradas da rede de inferência da entrada em regime permanente dos parâmetros de desempenho .....	64
Quadro 4 - Arquitetura da rede neural para o prognóstico do valor final .....	72
Quadro 5 - Valores arbitrados para os critérios de parada da rede de prognóstico .....	72
Quadro 6 - Entradas da rede de prognóstico do valor final dos parâmetros de desempenho .....	73
Quadro 7 - Divisão do conjunto selecionado por capacidade e fluido refrigerante .....	75
Quadro 8 - Divisão dos conjuntos de treinamento e validação .....	77
Quadro 9 - Conjunto de regras para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração .....	92
Quadro 10 - Quantidade de ensaios para cada regra adotada no comitê de inferência da capacidade de refrigeração .....	93
Quadro 11 - Tempos médios de inferência para cada regra .....	93
Quadro 12 - Conjunto de regras para o comitê de inferência da entrada em regime permanente do consumo .....	95
Quadro 13 - Quantidade de ensaios para cada regra adotada no comitê de inferência do consumo .....	95
Quadro 14 - Tempos médios de inferência para cada regra .....	95
Quadro 15 - Conjunto de regras para o comitê de inferência da entrada em regime permanente do COP .....	97
Quadro 16 - Quantidade de ensaios para cada regra adotada no comitê de inferência do COP .....	97
Quadro 17 - Tempos médios de inferência para cada regra .....	97
Quadro 18 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para a capacidade de refrigeração .....	99
Quadro 19 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para o consumo .....	101
Quadro 20 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para o COP .....	102
Quadro 21 - Resumo do desempenho do módulo neural da capacidade de refrigeração .....	103
Quadro 22 - Desempenho do módulo neural da capacidade de refrigeração para diferentes faixas de capacidade .....	105
Quadro 23 - Desempenho do módulo neural da capacidade de refrigeração para diferentes fluidos refrigerantes .....	106
Quadro 24 - Resumo do desempenho do módulo neural do consumo .....	106

Quadro 25 - Desempenho do módulo neural do consumo para diferentes faixas de capacidade .....	108
Quadro 26 - Desempenho do módulo neural do consumo para diferentes fluidos refrigerantes .....	109
Quadro 27 - Resumo do desempenho do módulo neural do COP .....	109
Quadro 28 - Desempenho do módulo neural do COP para diferentes faixas de capacidade .....	111
Quadro 29 - Desempenho do módulo neural do COP para diferentes fluidos refrigerantes .....	111
Quadro 30 - Resumo dos resultados dos módulos neurais.....	112
Quadro 31 - Resumo dos resultados dos módulos neurais em função da faixa de capacidade .....	113
Quadro 32 - Resumo dos resultados dos módulos neurais em função do fluido refrigerante .....	114
Quadro 33 - Comparação de desempenho entre ferramentas de inferência e prognóstico .....	115

## LISTA DE ABREVIATURAS E SÍMBOLOS

BIPM - *Bureau international des poids et mesures*

CAP - Capacidade de refrigeração

CONS - Consumo

COP - Coeficiente de performance

GUM - Guia para a expressão da incerteza de medição

ISO - *International organization for standardization*

P&D - Pesquisa e desenvolvimento

RNA - Rede neural artificial

VIM - Vocabulário internacional de termos fundamentais e gerais de metrologia

FN - Falso negativo

FP - Falso positivo

$h_{f1}$  - Entalpia no ponto de líquido saturado

$h_{f2}$  - Entalpia do líquido sub resfriado entrando no processo de expansão

$h_{g1}$  - Entalpia do vapor superaquecido entrando no processo de compressão

$h_{g2}$  - Entalpia no ponto de vapor saturado

$p_{g1}$  - Pressão de sucção do compressor

$p_{g2}$  - Pressão de descarga do compressor

$t_c$  - Temperatura de condensação

$t_o$  - Temperatura de evaporação

$t_{f2}$  - Temperatura do líquido sub resfriado prestes a expandir

$t_{g1}$  - Temperatura do vapor superaquecido prestes a entrar no compressor

$q_{mf}$  - Vazão mássica do fluido refrigerante

$\phi_i$  - Calor cedido pela fonte externa

$F_1$  - Fator de perdas do calorímetro

$t_a$  - Temperatura ambiente

$t_g$  - Temperatura interna do calorímetro

$\phi_0$  - Capacidade de refrigeração do compressor

$V_{ga}$  - Volume específico do vapor superaquecido entrando no compressor

$V_{gl}$  - Volume específico no ponto de vapor saturado



## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>25</b>
1.1 OBJETIVOS .....	28
<b>1.1.1 Objetivo Geral.....</b>	<b>28</b>
<b>1.1.2 Objetivos Específicos .....</b>	<b>28</b>
1.2 ESTRUTURA DO DOCUMENTO.....	29
<b>2 ENSAIOS DE DESEMPENHO ENERGÉTICO DE COMPRESSORES HERMÉTICOS .....</b>	<b>31</b>
2.1 CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR.....	31
2.2 DEFINIÇÃO DOS PARÂMETROS DE DESEMPENHO .....	33
2.3 MÉTODOS DE ENSAIO PARA MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO.....	34
<b>2.3.1 Método A – Calorímetro de fluido secundário .....</b>	<b>34</b>
<b>2.3.2 Método F – Medidor de vazão no estado líquido.....</b>	<b>36</b>
<b>2.3.3 Diferenças entre métodos .....</b>	<b>37</b>
2.4 REQUISITOS GERAIS DE ENSAIO .....	38
2.5 BANCADA DE ENSAIO DE DESEMPENHO ENERGÉTICO DE COMPRESSORES HERMÉTICOS .....	39
<b>3 REDES NEURAIS ARTIFICIAIS.....</b>	<b>43</b>
3.1 MODELO DE NEURÔNIO .....	45
3.2 ARQUITETURAS DE REDES NEURAIS .....	47
3.3 TREINAMENTO DE REDES NEURAIS.....	48
3.4 ASPECTOS RELACIONADOS À CONFIABILIDADE DE REDES NEURAIS.....	52
<b>3.4.1 Natureza estatística do processo de treinamento .....</b>	<b>52</b>
<b>3.4.2 Validação cruzada.....</b>	<b>55</b>
<b>3.4.3 Máquinas de Comitê.....</b>	<b>56</b>
3.5 INSERÇÃO DE CARACTERÍSTICAS DINÂMICAS EM MODELOS ESTÁTICOS DE REDES NEURAIS.....	57

<b>4 SISTEMA NEURAL PARA INFERÊNCIA DA ENTRADA EM REGIME E PROGNÓSTICO DO VALOR FINAL.....</b>	<b>59</b>
4.1 PANORAMA .....	59
4.2 FERRAMENTA PARA INFERÊNCIA DA ENTRADA EM REGIME PERMANENTE .....	60
4.2.1 Arquitetura da rede e algoritmo de treinamento .....	62
4.2.2 Variáveis de entrada.....	63
4.2.3 Pré-processamento das variáveis de entrada.....	65
4.2.4 Saída da rede.....	68
4.2.5 Estratégias para minimizar erro de falso positivo .....	69
4.3 FERRAMENTA PARA PROGNÓSTICO DO VALOR FINAL DE ENSAIO .....	71
4.3.1 Arquitetura da rede e algoritmo de treinamento .....	72
4.3.2 Variáveis de entrada.....	72
4.3.3 Pré-processamento das variáveis de entrada.....	73
4.3.4 Saída da rede.....	74
4.4 ANÁLISE DA BIBLIOTECA DE ENSAIOS .....	74
4.5 FORMAÇÃO DOS CONJUNTOS DE TREINAMENTO, VALIDAÇÃO E TESTE .....	77
4.6 COMITÊS DE REDES NEURAIS PARA INFERÊNCIA DE ENTRADA EM REGIME PERMANENTE .....	79
4.6.1 Comitê para inferência da entrada em regime permanente da capacidade de refrigeração.....	79
4.6.2 Comitê para inferência da entrada em regime permanente do consumo.....	83
4.6.3 Comitê para inferência da entrada em regime permanente do COP.....	86
4.7 INTEGRAÇÃO DAS REDES DE INFERÊNCIA DA ENTRADA EM REGIME PERMANENTE .....	88
4.7.1 Regras de integração do comitê de inferência da capacidade de refrigeração.....	89

<b>4.7.2 Regras de integração do comitê de inferência do consumo .....</b>	<b>93</b>
<b>4.7.3 Regras de integração do comitê de inferência do COP .....</b>	<b>96</b>
<b>4.8 COMITÊS DE REDES NEURAIIS PARA PROGNÓSTICO DO VALOR FINAL DE ENSAIO.....</b>	<b>98</b>
<b>4.8.1 Comitê para prognóstico do valor final da capacidade de refrigeração.....</b>	<b>98</b>
<b>4.8.2 Comitê para prognóstico do valor final do consumo .....</b>	<b>100</b>
<b>4.8.3 Comitê para prognóstico do valor final do COP .....</b>	<b>101</b>
<b>5 ANÁLISE DOS RESULTADOS .....</b>	<b>103</b>
<b>5.1 MÓDULO NEURAL DA CAPACIDADE DE REFRIGERAÇÃO .....</b>	<b>103</b>
<b>5.1.1 Análise por faixas de capacidade.....</b>	<b>104</b>
<b>5.1.2 Análise por fluido refrigerante .....</b>	<b>105</b>
<b>5.2 MÓDULO NEURAL DO CONSUMO .....</b>	<b>106</b>
<b>5.2.1 Análise por faixas de capacidade.....</b>	<b>107</b>
<b>5.2.2 Análise por fluido refrigerante .....</b>	<b>108</b>
<b>5.3 MÓDULO NEURAL DO COP .....</b>	<b>109</b>
<b>5.3.1 Análise por faixas de capacidade.....</b>	<b>110</b>
<b>5.3.2 Análise por fluido refrigerante .....</b>	<b>111</b>
<b>5.4 DISCUSSÃO DOS RESULTADOS .....</b>	<b>112</b>
<b>5.5 ANÁLISE DE DESEMPENHO DAS FERRAMENTAS DE INFERÊNCIA E PROGNÓSTICO .....</b>	<b>115</b>
<b>6 CONSIDERAÇÕES FINAIS .....</b>	<b>119</b>
<b>6.1 CONCLUSÕES .....</b>	<b>119</b>
<b>6.2 SUGESTÕES DE TRABALHOS FUTUROS.....</b>	<b>121</b>
<b>REFERÊNCIAS .....</b>	<b>123</b>





## 1 INTRODUÇÃO

Com o aumento da competitividade e dos padrões de qualidade nas últimas décadas, empresas fabricantes de compressores herméticos necessitam investir cada vez mais em pesquisa e desenvolvimento (P&D) de forma a se manterem competitivas. Dentro desse contexto, investimentos em centros avançados de P&D, além de parcerias com centros universitários de pesquisa tornam-se imperativos para a manutenção da competitividade dos produtos. Dentre os objetivos de tamanho investimento, destaca-se a contínua busca pela melhoria da eficiência energética dos seus produtos, um dos fatores decisivos de mercado.

Dentre os diversos ensaios realizados em compressores herméticos, destacam-se os ensaios de desempenho energético (capacidade de refrigeração, potência elétrica consumida e coeficiente de performance). Tais ensaios são utilizados para vários fins, dentre eles: controle de qualidade do processo produtivo, obtenção de dados para catálogos, análise de novos produtos (PENZ, 2011). Os mesmos são realizados em larga escala e representam um custo significativo de recursos de tempo e dinheiro. Tal fato acaba por gerar um gargalo no contínuo processo de otimização e controle de qualidade.

Os ensaios de desempenho energético seguem normas que estabelecem diretrizes para obtenção dos parâmetros de desempenho de forma a garantir a confiabilidade dos resultados. Dentre as condições especificadas, destaca-se a necessidade de o compressor permanecer em regime permanente, em um sistema de refrigeração padronizado, por pelo menos uma hora para que as medições sejam validadas (ISO 917, 1989; ASHRAE 23, 2005). Em bancadas pouco automatizadas, o tempo para se atingir tal regime é, em média, de 3 horas (PENZ, 2011). Sendo assim, o tempo médio para realização de um ensaio é de 4 horas. As normas também preveem a utilização de dois métodos distintos para a medição da vazão mássica e, conseqüentemente, da capacidade de refrigeração. É estabelecido que a diferença dos resultados obtidos pelos dois métodos não pode passar de 4% (ISO 917, 1989).

Com isso em mente, estudos foram iniciados com o objetivo de buscar soluções para diminuir o tempo de execução de tais ensaios e, ao mesmo tempo, garantir a confiabilidade metrológica dos resultados.

Os primeiros trabalhos realizados neste contexto focaram na otimização da bancada de desempenho de compressores. Enquanto alguns focaram no melhoramento da confiabilidade metrológica das grandezas medidas (BARBOSA, 2006; FLESCH, 2006; PETROVIC, 2007;

POLLETO, 2006), outros tiveram como objetivo a diminuição do tempo necessário para o sistema atingir o regime permanente (LIMA, 2010a; SCUSSEL, 2006; SILVEIRA, 2010).

Os resultados dos trabalhos iniciais foram animadores. Houve reduções consideráveis nas incertezas de medição das grandezas e o tempo de ensaio teve uma redução média de 50% (PENZ, 2011).

Em paralelo com o melhoramento do *hardware* e controle da bancada, uma segunda estratégia foi utilizada na busca pela diminuição do tempo de ensaio. A mesma, parte da utilização de técnicas de inteligência artificial para a inferência<sup>1</sup> do momento de entrada dos parâmetros de interesse no regime permanente, seguido de um prognóstico<sup>2</sup> do valor final de tal parâmetro baseado na inferência. Em outras palavras, a estratégia consiste na utilização de um sistema que avalia a tendência dos dados de determinado parâmetro de interesse e, a partir de um aprendizado prévio, consegue inferir se, no momento analisado, o mesmo encontra-se ou não em regime permanente. Em seguida, a partir da verificação do ponto de entrada em regime, é realizado um prognóstico do valor final do parâmetro. No ensaio normatizado, o ponto de entrada em regime permanente só pode ser verificado ao final do ensaio.

A aplicação dessa segunda abordagem teve como escopo o desenvolvimento de uma alternativa para a medição das variáveis de desempenho que fosse mais rápida, não substituindo, contudo, o ensaio normatizado. O objetivo inicial seria a utilização da mesma em pesquisa e desenvolvimento de novos compressores, podendo ser utilizada também no controle de qualidade, caso atingisse suficiente robustez.

Nos primeiros trabalhos, foram utilizadas diversas técnicas de inteligência artificial para verificação da adequação das mesmas ao problema em questão. Dentre as técnicas utilizadas pode-se destacar a aplicação de redes neurais artificiais, lógica nebulosa (fuzzy) e redes fuzzy-bayesianas (CASELLA, 2008; HENKLEIN, 2006; STEINBACH, 2008). Os resultados se mostraram promissores e uma quarta dissertação de mestrado (LIMA, 2010b) foi encaminhada.

Lima (2010b) conseguiu com sucesso desenvolver e implementar um conjunto de ferramentas de redes neurais artificiais (RNA) para

---

<sup>1</sup> Inferência - operação intelectual pela qual se passa de uma verdade a outra, julgada tal em razão de seu liame com a primeira: a dedução é uma inferência (AURÉLIO, 2014).

<sup>2</sup> Prognóstico - ato ou efeito de prognosticar. / Previsão, suposição sobre o que deve acontecer (AURÉLIO, 2014).

inferência do ponto de entrada em regime permanente e prognóstico do valor final dos três parâmetros de interesse nos ensaios de desempenho: capacidade de refrigeração, potência elétrica consumida e coeficiente de performance.

Os resultados da aplicação dessas ferramentas nas bancadas de ensaios de desempenho apresentaram reduções de tempo de, pelo menos, 50% em relação aos ensaios padronizados (LIMA, 2010b). A forma de avaliação do desempenho das ferramentas foi feita através da diferença entre o prognóstico obtido e o valor final do ensaio padronizado.

A validação do método, no entanto, mostrou-se mais desafiadora. Uma vez que as redes neurais foram utilizadas para obtenção do prognóstico das variáveis de desempenho, as mesmas fazem parte do sistema de medição proposto. No entanto, a avaliação da incerteza de uma medição obtida através de técnicas de inteligência artificial está longe dos atuais conceitos metroológicos (PENZ, 2011).

Tendo em vista os promissores resultados obtidos através da aplicação das ferramentas de inteligência artificial, Penz (2011) buscou desenvolver procedimentos para prover confiabilidade aos resultados obtidos.

Partindo das ferramentas desenvolvidas por Lima (2010b), Penz (2011) realizou estudos a respeito de métodos alternativos ao ISO-GUM – documento referência para estimativa de incerteza de medição (BIPM, 2008) – para avaliação da confiabilidade dos resultados obtidos através das redes neurais<sup>3</sup>. O mesmo conseguiu aumentar a confiabilidade dos resultados através da implementação de um conjunto de redes aliada ao uso de informações *a priori*. Os resultados obtidos mostraram uma melhora expressiva em comparação às primeiras ferramentas obtidas por Lima (2010b). No entanto, os estudos realizados por Penz (2011) ficaram limitados à capacidade de refrigeração, não contemplando o uso de redes para prognósticos da potência elétrica consumida e do coeficiente de performance.

Um problema encontrado, tanto por Lima (2010b) quanto por Penz (2011) durante seus trabalhos, foi o baixo número de ensaios disponíveis para o treinamento e teste das redes neurais. Tanto Lima (2010b) quanto Penz (2011) utilizaram 61 ensaios para treinar as redes. Embora esse número tenha sido suficiente para a obtenção de resultados expressivos, uma quantidade maior de ensaios se mostra interessante na busca pelo aumento da confiabilidade dos resultados dos prognósticos. Outra

---

<sup>3</sup> Ao longo do texto, quando houver citação às redes neurais, entende-se que o autor esteja se referindo às redes neurais artificiais.

constante nos dois trabalhos foi o uso dos sinais de capacidade de refrigeração obtidos através da medição de vazão mássica com um medidor de vazão mássica em estado líquido. Tal método não é o mais usual para a medição da capacidade, sendo a medição através de um calorímetro de fluido secundário, o mais utilizado na indústria.

Passado algum tempo da instalação e uso das bancadas de ensaio de desempenho energético desenvolvidas nos primeiros trabalhos dessa linha de pesquisa, uma quantidade expressiva de ensaios já se encontra disponível para utilização nos estudos de redes neurais. Aliando isso ao fato de que os estudos para aumento da confiabilidade dos resultados obtidos por redes neurais realizados por Penz (2011) não contemplaram os parâmetros de desempenho: potência elétrica consumida e coeficiente de performance, tem-se uma oportunidade de estudo sobre a confiabilidade das redes em ensaios de desempenho de compressores utilizando recursos não antes disponíveis.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo Geral

O objetivo deste trabalho é aprimorar as ferramentas disponíveis para inferência e prognóstico dos três principais parâmetros obtidos pelo ensaio de desempenho energético através da utilização de uma quantidade expressiva de ensaios para o treinamento e teste das mesmas.

### 1.1.2 Objetivos Específicos

- Verificar a possibilidade de utilizar ensaios que empreguem medições feitas através de calorímetros de fluido secundário, mais comum na indústria, ao invés de medidores diretos de vazão mássica;
- Desenvolver ferramentas para inferência e prognóstico da potência elétrica consumida e do coeficiente de performance de acordo com estratégias definidas por Penz (2011) para a capacidade de refrigeração;
- Analisar a qualidade dos prognósticos apresentados pelas ferramentas desenvolvidas empregando-se biblioteca com mais de mil ensaios;

- Estabelecer uma estratégia específica para integrar as respostas das diversas redes neurais utilizadas nos processos de inferência do regime permanente e prognóstico do valor final de ensaio;
- Obter resultados de prognóstico para os parâmetros de desempenho com diferenças, em relação ao valor final de ensaio, não superiores aos seguintes limites:
  - Capacidade de refrigeração:  $\pm 2\%$  do valor final de ensaio;
  - Potência elétrica consumida:  $\pm 2\%$  do valor final de ensaio;
  - Coeficiente de performance:  $\pm 3\%$  do valor final de ensaio.

Tais limites foram arbitrados em trabalhos anteriores e estão fundamentados na diretriz da norma ISO 917 (1989), que indica uma diferença de até 4% entre os dois métodos de medição da vazão mássica, e consequentemente da capacidade de refrigeração, como sendo aceitáveis.

## 1.2 ESTRUTURA DO DOCUMENTO

O capítulo 2 engloba um estudo a respeito do ensaio de desempenho energético de compressores herméticos. São abordados os métodos de medição e os requisitos exigidos pelas normas. O capítulo 3 trata dos conceitos básicos de redes neurais artificiais necessários para o entendimento do trabalho. O capítulo 4 aborda na sequência: a descrição das ferramentas para inferência da entrada em regime permanente e prognóstico do valor final de ensaio, a análise da biblioteca de ensaios, a implementação das novas ferramentas. O capítulo 5 aborda a análise dos resultados obtidos através das novas ferramentas. No capítulo 6 são apresentadas as conclusões deste trabalho e propostas de trabalhos futuros.



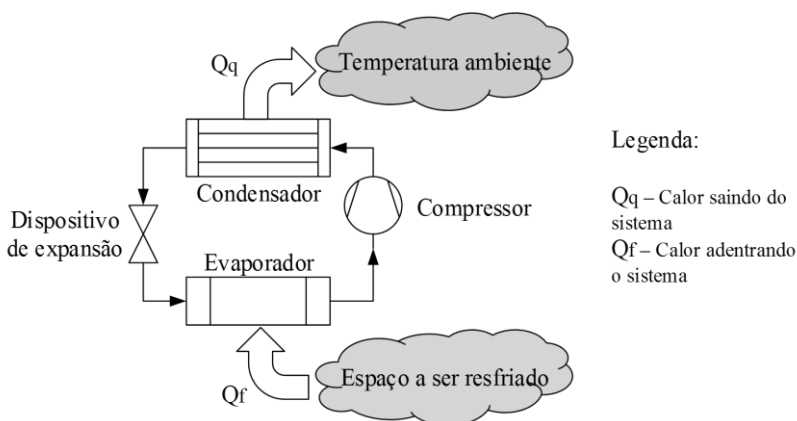
## 2 ENSAIOS DE DESEMPENHO ENERGÉTICO DE COMPRESSORES HERMÉTICOS

Dentre as normas utilizadas para a padronização dos ensaios de desempenho energético de compressores, a ISO 917: “*Testing of refrigerant compressor*” (1989) e a ANSI/ASHRAE 23: “*Methods of Testing for Rating Positive Displacement Refrigerant compressors and Condensing Units*” (2005) são consideradas as mais consolidadas e internacionalmente aceitas no meio industrial. A metodologia prevista nas mesmas tem como objetivo a determinação da capacidade de refrigeração, potência elétrica consumida e o coeficiente de performance do compressor. Tais testes fornecem resultados com confiabilidade suficiente para avaliar se o compressor está adequado para operar satisfatoriamente em qualquer condição de operação requerida em um sistema de refrigeração (ISO 917, 1989).

### 2.1 CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR

O ensaio de desempenho energético de compressores utiliza um ciclo de refrigeração por compressão de vapor para a obtenção dos parâmetros de desempenho. Desta forma, o compressor a ser ensaiado é acoplado a um sistema contendo um condensador, um evaporador e um dispositivo de expansão. Tal configuração pode ser vista na figura 1.


Figura 1 - Ciclo de refrigeração por compressão de vapor



Fonte: Adaptado de Çengel (2006).

O diagrama de pressão x entalpia de um ciclo ideal de refrigeração por compressão de vapor é apresentado na figura 2. O processo é dividido em 4 etapas. A primeira é uma compressão isentrópica do refrigerante. Percebe-se pelo diagrama que o refrigerante entra no compressor na condição de vapor saturado e é comprimido até atingir a pressão de descarga. A segunda etapa consiste de uma condensação isobárica deste refrigerante até o ponto de líquido saturado. Uma parcela de energia em forma de calor é removida do sistema. Em seguida, é realizada uma expansão isentálpica. Por último, o refrigerante passa por uma evaporação isobárica e isotérmica, visto que a temperatura permanece constante durante etapas de mudança de fase. Nesta última etapa, uma parcela de energia em forma de calor é absorvida pelo sistema. Tal absorção é o objetivo dos ciclos de refrigeração.

Figura 2 - Diagrama pressão x entalpia do ciclo ideal de refrigeração por compressão de vapor



Legenda:

Processo 1-2	Compressão isentrópica	Processo 3-4	Expansão isentálpica
Processo 2-3	Condensação isobárica	Processo 4-1	Evaporação isobárica e isotérmica


Fonte: Adaptado de Çengel (2006).

Como tais processos acabam sofrendo com o atrito do fluido nos componentes e a transferência de calor com a vizinhança, etapas intermediárias são adicionadas de forma a garantir o funcionamento correto do sistema. Na figura 3, o ciclo ideal é novamente apresentado, mas com duas etapas adicionais. Para garantir que apenas vapor entre no compressor, uma etapa de superaquecimento é adicionada entre os estágios 4 e 1. Da mesma forma, uma etapa de sub-resfriamento pode ser



adicionada entre os estágios 2 e 3 de forma a garantir que apenas líquido entre no dispositivo de expansão.

Figura 3 - Ciclo ideal de refrigeração por compressão de vapor com etapas adicionais



Fonte: Adaptado de ASHRAE 23 (2005).

## 2.2 DEFINIÇÃO DOS PARÂMETROS DE DESEMPENHO

Potência elétrica consumida<sup>4</sup>: é a potência nos terminais do compressor hermético, sendo a soma do consumo do compressor e de outros dispositivos auxiliares necessários para o funcionamento do mesmo (ISO 917, 1989). Tal parâmetro é expresso em watt.

Capacidade de refrigeração ( $\Phi_0$ ): é o produto da vazão mássica de fluido refrigerante através do compressor pela diferença entre a entalpia específica do refrigerante na entrada do compressor e a entalpia específica do líquido saturado na temperatura correspondente à pressão de descarga na saída do mesmo (ISO 917, 1989). Em uma segunda definição, é o

<sup>4</sup> Ao longo do trabalho, tal parâmetro será chamado de consumo.

produto da vazão mássica de fluido refrigerante através do compressor pela diferença entre a entalpia específica do refrigerante na entrada do compressor e a entalpia específica do líquido sub-resfriado na entrada do dispositivo de controle da pressão de sucção (ANSI/ASHRAE 23, 2005). A diferença entre as duas definições será abordada mais adiante. Este parâmetro é também expresso em watt.

Coefficiente de performance: razão da capacidade de refrigeração pela potência elétrica consumida (ISO 917, 1989). É uma grandeza adimensional.

## 2.3 MÉTODOS DE ENSAIO PARA MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO

A norma ISO 917 (1989) prevê nove métodos diferentes para medir a vazão mássica do fluido refrigerante e, consequentemente, a capacidade de refrigeração. Estabelece ainda que dois métodos devem ser utilizados simultaneamente para que a medição possa ser validada. Como alguns dos métodos são muito semelhantes, a norma especifica quais combinações podem ser feitas de modo que os resultados obtidos por um método sejam independentes dos resultados obtidos por outro. A norma também prevê que a diferença entre os resultados dos dois métodos não pode passar de 4% entre os métodos (ISO 917, 1989). Em contrapartida, a norma ASHRAE 23 (2005) prevê seis diferentes métodos para obtenção da vazão. Novamente, dois métodos devem ser utilizados simultaneamente.

Como os ensaios disponíveis para análise neste trabalho utilizam apenas dois dos métodos disponíveis, apenas estes serão detalhados.

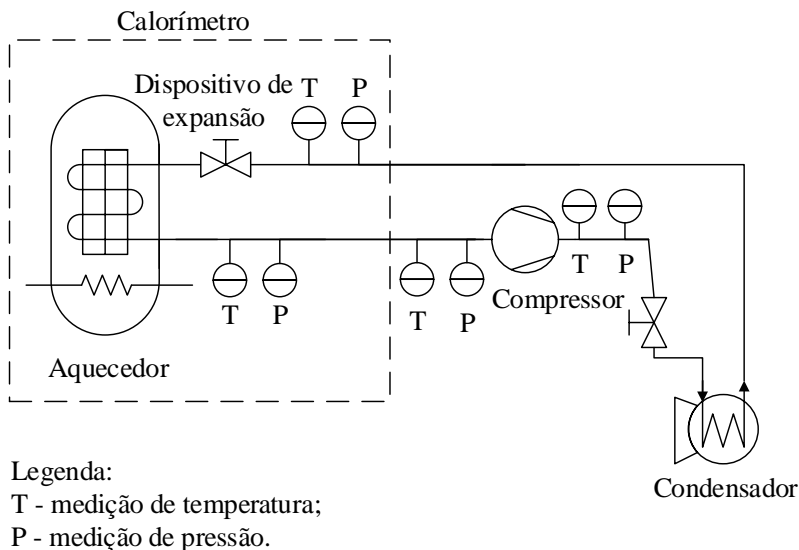
### 2.3.1 Método A – Calorímetro de fluido secundário

Utiliza um ciclo de compressão de vapor para a medição da vazão mássica do fluido refrigerante através da troca de calor entre o fluido refrigerante e um fluido secundário dentro do evaporador. Tal evaporador é suspenso na parte mais alta de um vaso de pressão hermético e isolado termicamente (ISO 917, 1989). Um resistor, localizado na base do vaso, aquece o fluido secundário que, por sua vez, troca calor com o fluido refrigerante através da serpentina do evaporador.

A vazão de fluido refrigerante no interior da serpentina é controlada por um dispositivo de expansão manual, ou de pressão constante, localizada próximo ao calorímetro. O mesmo deve ser isolado

de tal forma que a perda de calor não seja maior que 5%. Uma ilustração do circuito é apresentada na figura 4.

Figura 4 - Calorímetro de fluido secundário



Fonte: Adaptado de ISO 917 (1989).

Enquanto a norma ISO 917 (1989) apenas recomenda a utilização de estágios de superaquecimento e sub-resfriamento – discutidos na seção 2.3 - a norma ANSI/ASHRAE 41.9 (2000) exige que o fluido refrigerante que sai do calorímetro possua pelo menos 2,8°C de superaquecimento. Da mesma forma, o fluido que entra no calorímetro deve apresentar pelo menos 5,6°C de sub-resfriamento. Tal exigência acaba por refletir na forma como cada norma calcula a vazão mássica e a capacidade de refrigeração. Para a norma ISO 917, as equações (1) e (2) são utilizadas para obtenção destas duas variáveis.

$$q_{mf} = \frac{\dot{Q}_i + F_1(t_a - t_g)}{h_{g2} - h_{f2}} \quad (1)$$

$$\phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad (2)$$

Já para a norma ASHRAE 23, as equações (3) e (4) são utilizadas.

$$q_{mf} = \frac{\phi_i + F_1(t_a - t_g)}{h_{g1} - h_{f2}} \quad (3)$$

$$\phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f2}) \quad (4)$$

Sendo:

$q_{mf}$	vazão mássica do fluido refrigerante	[kg/s]
$\phi_i$	calor cedido pela fonte externa	[kJ]
$F_1$	fator de perdas do calorímetro	[kJ/K]
$t_a$	temperatura ambiente	[K]
$t_g$	temperatura interna do calorímetro	[K]
$h_{g2}$	entalpia no ponto de vapor saturado	[kJ/kg]
$h_{f2}$	entalpia do líquido sub-resfriado entrando no processo de expansão	[kJ/kg]
$h_{g1}$	entalpia do vapor superaquecido entrando no processo de compressão	[kJ/kg]
$h_{f1}$	entalpia no ponto de líquido saturado	[kJ/kg]
$\phi_0$	capacidade de refrigeração do compressor	[W]
$V_{ga}$	volume específico do vapor superaquecido entrando no compressor	[m <sup>3</sup> /kg]
$V_{gl}$	volume específico no ponto de vapor saturado	[m <sup>3</sup> /kg]


### 2.3.2 Método F – Medidor de vazão no estado líquido

Utiliza um medidor de vazão para obter a vazão mássica do fluido refrigerante no estado líquido. Tal medidor utiliza o efeito coriolis como princípio de medição. O medidor deve ser posicionado entre o reservatório de fluido e o dispositivo de expansão (ISO 917, 1989). Para garantir o estado líquido do fluido quando da passagem pelo medidor, um sub-resfriador deve ser adicionado ao sistema, conforme apresentado na figura 5. Utilizando o valor obtido no medidor, a capacidade de



calculados através de um balanço térmico, tal método torna-se muito mais susceptível à inércia térmica do sistema.

Figura 6 - Dinâmica da capacidade para diferentes métodos de medição



Fonte: Autor.

## 2.4 REQUISITOS GERAIS DE ENSAIO

As medições que serão utilizadas para o cálculo dos parâmetros de desempenho deverão ser realizadas somente após o compressor atingir o regime permanente. Tal regime é alcançado quando as flutuações de todas as variáveis que estão sendo medidas permanecerem dentro dos limites preestabelecidos por um determinado intervalo de tempo, não mostrando tendência definitiva a se mover para fora desses limites (ISO 917, 1989). A chegada real ao regime permanente, no entanto, só é observada ao final do ensaio, visto que somente então as medições poderão ser comparadas ao valor final do ensaio. Os limites das flutuações das variáveis são:

- leituras de pressão com variação menor que  $\pm 1$  % do valor de referência;
- leituras de temperatura com variação menor que  $\pm 3$  K em relação ao valor de referência;
- tensão de alimentação do compressor com variação menor que  $\pm 3$  % do valor de referência;
- no método A, no qual o aquecimento elétrico é utilizado, a potência fornecida aos resistores de aquecimento deve ser mantida com variação máxima de  $\pm 1$  % do valor lido;
- no método F, a variação no medidor de fluxo de massa não pode exceder o limite de  $\pm 1$  % do valor lido.

Uma vez atingidos tais limites, medições das variáveis devem ser realizadas. Para a norma ISO 917, tais medições devem ser feitas ao longo de uma hora, com espaçamentos iguais, não ultrapassando 20 minutos entre cada medição. O valor final de cada parâmetro será a média aritmética de todas as medições (ISO 917, 1989). Já para a norma ASHRAE 23 (2005), ao menos três medições devem ser realizadas no regime permanente. A média de todas as medições será considerada como o valor final de cada parâmetro, sendo que a variação de cada medição em relação à média não pode ultrapassar  $\pm 2$  %.

As normas não especificam limites de variação aceitáveis para a constatação do regime permanente da capacidade de refrigeração, da potência elétrica consumida e da temperatura da carcaça do compressor. No entanto, especialistas arbitram limites aceitáveis como sendo (PENZ, 2011):

- capacidade:  $\pm 2$  % do valor final de ensaio;
- consumo:  $\pm 2$  % do valor final de ensaio;
- temperatura carcaça:  $\pm 1$  K do valor final de ensaio.

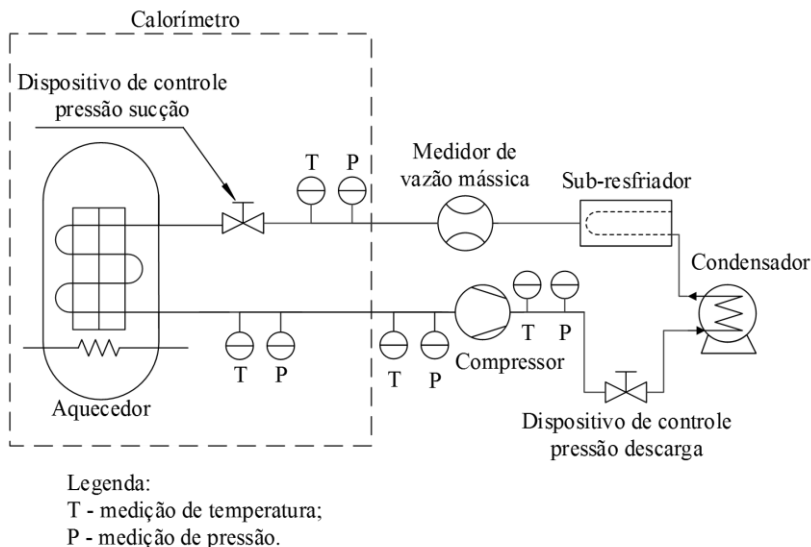
## 2.5 BANCADA DE ENSAIO DE DESEMPENHO ENERGÉTICO DE COMPRESSORES HERMÉTICOS

Dependendo dos métodos de medição que serão utilizados, as bancadas para ensaio de desempenho energético podem variar sua arquitetura, contudo, é claro, que cumpram as exigências contidas na norma.

Na figura 7 é possível visualizar o circuito da bancada de desempenho desenvolvida em trabalhos anteriores (BARBOSA, 2006;

FLESCH, 2006; LIMA, 2010a; PETROVCIC, 2007; POLLETO, 2006; SCUSSEL, 2006; SILVEIRA, 2010).

Figura 7 - Circuito da bancada de desempenho desenvolvida em trabalhos anteriores



Fonte: Adaptado de Flesch (2006).

Essa bancada foi desenvolvida utilizando os métodos de medição A e F, os mesmos utilizados por empresas de referência no controle de qualidade de seus produtos.

As condições de operação para realização dos ensaios são padronizadas e definem a temperatura de evaporação, condensação e, por consequência, as pressões absolutas de sucção e descarga para o fluido refrigerante em questão. Os dispositivos de controle da pressão de sucção e descarga, assim como as resistências de aquecimento, são os responsáveis por levarem o circuito à condição de operação.

Dentre os grandes avanços obtidos nos trabalhos anteriores, destacam-se as melhorias realizadas no sistema de controle para que as variáveis atinjam as condições de teste o mais rapidamente possível, diminuindo assim o tempo em que o sistema leva para atingir o regime permanente. Para tal, diversas variáveis devem ser monitoradas e controladas (SCUSSEL, 2006). São elas:



- pressão de descarga;
- pressão de sucção;
- temperatura da sucção;
- tensão e corrente elétrica da alimentação do compressor;
- temperatura e velocidade do fluxo de ar em torno do compressor;
- temperatura interna ao trocador de calor (evaporador);
- temperatura externa ao trocador de calor (evaporador);
- vazão e temperatura da água de condensação;
- potência elétrica entregue ao compressor;
- sub-resfriamento do fluido refrigerante na entrada do calorímetro.

A automatização completa do sistema permite a eliminação da intervenção do operador, contribuindo para a melhoria da repetibilidade e reprodutibilidade dos ensaios. Tal fato auxilia futuras pesquisas que utilizem esses ensaios, uma vez que contribui para o aumento da confiabilidade metrológica dos mesmos.



### 3 REDES NEURAIS ARTIFICIAIS

Rede Neural Artificial (RNA) é uma das técnicas de inteligência artificial (IA). Não existe uma definição única para inteligência artificial. Ao longo de sua história, vários pesquisadores tentaram definir o conceito com base no seu campo de pesquisa. Dentre as várias definições, pode-se citar: “IA é o estudo e implementação de agentes racionais” (RUSSEL e NORVIG, 2003). Um agente racional é qualquer entidade com capacidade de percepção e ação que procura atingir seus objetivos através de seus conhecimentos e crenças. Dentro desta abordagem, IA é vista como o estudo e construção de agentes racionais.

Ao longo dos anos, diferentes caminhos foram utilizados de forma a desenvolver sistemas inteligentes. Um sub-ramo da IA que engloba várias das abordagens mais exploradas na atualidade é a Inteligência Computacional, que pode ser definida como: “o estudo de mecanismos adaptativos para permitir comportamento inteligente em ambientes complexos e em constante mudança” (ENGELBRECHT, 2007). Este ramo inclui as abordagens que exibem as habilidades de aprender ou se adaptar a novas situações e realizar generalizações<sup>5</sup>. Podem ser destacadas as abordagens de Redes Neurais Artificiais, Inteligência Evolutiva, Inteligência de Enxames e Sistemas Fuzzy.

A abordagem de RNA, também conhecida como conexionista, tem como objetivo a mimetização do sistema neural biológico. O cérebro é um computador complexo, não-linear e paralelo. O mesmo tem a capacidade de executar tarefas como reconhecimento de padrões, percepção e controle motor de forma muito mais eficiente do que qualquer computador atual (HAYKIN, 2001). Adicionalmente, habilidades como aprendizado, memorização e generalização levaram pesquisadores a buscar algoritmos que modelassem tais funções.

Redes Neurais Artificiais podem ser definidas como máquinas projetadas para modelar a forma com a qual o cérebro executa uma atividade ou função de interesse. Geralmente, são implementadas utilizando componentes eletrônicos ou simuladas através de softwares em computadores. As mesmas são semelhantes ao cérebro em dois aspectos: o conhecimento é adquirido pela rede através de um processo de treinamento e o conhecimento é armazenado através das conexões entre neurônios, conhecidas como pesos sinápticos (HAYKIN, 2001).

---

<sup>5</sup> Generalização se refere a capacidade de uma IA de produzir respostas adequadas para situações que não estavam presentes durante a fase de aprendizagem (HAYKIN, 2001).

Dentre as principais características das RNA, podem-se destacar (HAYKIN, 2001):

- capacidade de aprender através de exemplos (treinamento);
- capacidade de generalizar;
- elevada imunidade ao ruído (desempenho não colapsa na presença de informações falsas ou ausentes);
- bom desempenho em problemas “mal definidos” (nos quais não existe conhecimento de modelos matemáticos para o sistema);
- adaptabilidade (redes treinadas para uma determinada situação podem ser re-treinadas para lidar com mudanças no ambiente de uso). Existem tipos de RNA que se adaptam a novas situações em tempo real.

Tais características tornam as Redes Neurais Artificiais ferramentas muito interessantes para solução de problemas como inferências, prognóstico e classificação de variáveis complexas, de difícil modelamento matemático. Como exemplo, podem-se citar a utilização de redes neurais para o prognóstico de propriedades mecânicas de ligas metálicas (SINGARAM, 2011), previsão de parâmetros de desempenho de motores (GHOBADIAN, 2009), previsão de aspectos de qualidade na indústria de papel (EDWARDS, 2002), previsão de grandezas presentes em plantas nucleares (ZIO, 2006) e na previsão de recursos hidrológicos e meteorológicos (TRICHAKIS, 2011)

A utilização de redes neurais na indústria como uma alternativa aos testes de controle de qualidade se apresenta como uma opção interessante, uma vez que permite redução de custos e tempo, por vezes substituindo a necessidade de ensaios experimentais.

No tocante à utilização dessas ferramentas para previsão de variáveis relacionadas a sistemas de refrigeração, alguns estudos podem ser citados. Ertunc e Hosoz (2006) utilizaram tais ferramentas no prognóstico de vários parâmetros de performance de um sistema de refrigeração com um compressor a vapor. Abdelwahed *et al* (2012) utilizaram redes neurais para o prognóstico da qualidade da montagem de compressores a partir de parâmetros de qualidade das peças. Mohanraj, Jayaraj e Muraleedharan (2012) analisaram mais de 90 artigos relacionados à aplicação de redes neurais em sistemas de refrigeração. Os trabalhos realizados pelo grupo de pesquisa do qual o autor deste trabalho é membro, já citados na introdução, também são adicionados a esta lista.

### 3.1 MODELO DE NEURÔNIO

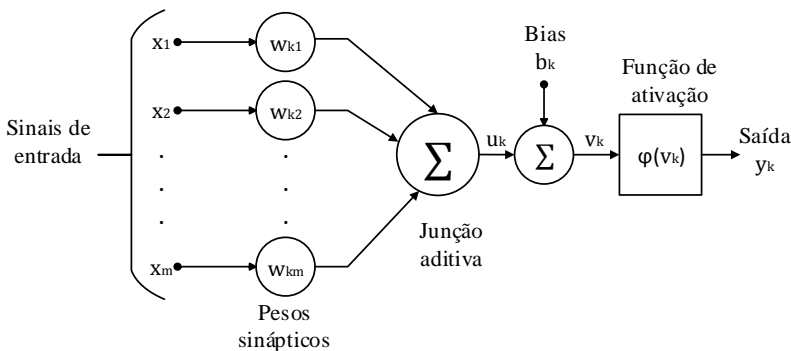
Neurônios são unidades de processamento de informação fundamentais para operação das redes neurais. Em sua concepção básica, cada neurônio é composto de três elementos: um conjunto de sinapses (sinais de entrada + pesos sinápticos), uma função de junção (tipicamente somatório) e uma função de ativação (limita a amplitude da saída do neurônio). O modelo neural possui também um *bias*  $b_k$ , que pode ser interpretado como uma entrada adicional com peso sináptico unitário (HAYKIN, 2001). A figura 8 ilustra o funcionamento de um neurônio de redes neurais. Cada entrada  $x_n$  é multiplicada pelo respectivo peso sináptico  $w_{kn}$  e em seguida somada às outras, gerando  $u_k$ , como indicado na equação (5). Após ser somado ao *bias*, na equação (6), tal valor é então submetido à função de ativação para gerar a saída  $y_k$ , através da equação (7).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (5)$$

$$v_k = u_k + b_k \quad (6)$$

$$y_k = \varphi(v_k) \quad (7)$$


Figura 8 - Modelo de neurônio



Fonte: Adaptado de Haykin (2001).


A função de ativação mais básica é a função limiar (MCCULLOCH e PITTS, 1943), descrita na figura 9. A utilização da mesma é limitada às redes de uma camada, não podendo ser utilizadas em redes mais complexas.

Figura 9 - Comportamento da função de ativação limiar



Fonte: Adaptado de Haykin (2001).

Figura 10 - Comportamento de funções sigmóides



Fonte: Adaptado de Haykin (2001).

As funções de ativação mais utilizadas na construção de redes neurais artificiais são as sigmóides. Dois exemplos deste tipo de função são apresentados na figura 10. Por possuírem derivadas suaves (que não variam bruscamente), são as mais indicadas para redes com mais de uma camada de neurônios. Segundo Haykin (2001), o aprendizado destas redes tende a ser mais rápido quando a função de ativação sigmoide utilizada pelos neurônios é antissimétrica, ou ímpar. Sendo assim, a função tangente hiperbólica, apresentada na figura 10, seria mais vantajosa em relação a função logística.


### 3.2 ARQUITETURAS DE REDES NEURAIS

Qualquer disposição organizada de neurônios conectados entre si pode ser considerada uma arquitetura de rede neural (HAYKIN, 2001). No entanto, certas características podem ser utilizadas para separar tais arquiteturas em diferentes classes. As características mais utilizadas para tal fim são: número de camadas na rede, tipo de conexões entre os neurônios e grau de conectividade entre os mesmos.

No quesito de conexão entre neurônios, as redes neurais se dividem em alimentadas adiante e recorrentes. Em redes alimentadas adiante – ou redes *feedforward* – as saídas dos neurônios só podem ser conectadas às entradas de neurônios da camada subsequente, nunca da mesma camada ou de camadas anteriores, fazendo com que o fluxo dos dados siga um caminho unidirecional dentro da rede. Já em redes recorrentes, laços de realimentação são utilizados para conectar saídas de neurônios às entradas de neurônios de camadas anteriores ou da mesma camada. Tal ação tem impacto profundo na capacidade de aprendizado da rede, assim como no seu desempenho (HAYKIN, 2001).

Em relação ao grau de conectividade entre os neurônios, uma rede é considerada totalmente conectada quando cada um dos neurônios de uma camada da rede está conectado a todos os neurônios da camada seguinte. Caso isto não aconteça, a rede será considerada parcialmente conectada.

A figura 11 apresenta um exemplo de rede *feedforward* multicamada e totalmente conectada. A mesma apresenta cinco entradas, três neurônios na camada intermediária e dois na camada de saída.

Figura 11 - Exemplo de rede *feedforward* multicamada

Fonte: Autor.

Não existem regras claras para a escolha do número de neurônios e camadas intermediárias, sendo na maioria das vezes um processo iterativo. No entanto, existem algoritmos de otimização que podem ser utilizados para facilitar a busca por tais parâmetros (MENDEL e MCLAREN, 1970). A adição de mais camadas permite o aprendizado de tarefas mais complexas através da extração progressiva de características mais significativas dos padrões de entrada (HAYKIN, 2001), mas ao mesmo tempo aumenta o custo computacional para realizar o treinamento da rede.

### 3.3 TREINAMENTO DE REDES NEURAIIS

No contexto de redes neurais, treinamento pode ser definido como um processo no qual, parâmetros livres de uma rede neural são adaptados através de um processo contínuo de estímulo do ambiente no qual a rede está inserida (MENDEL e MCLAREN, 1970). O tipo de treinamento é determinado através da forma com a qual os parâmetros são alterados. Os parâmetros em questão são os pesos sinápticos e o *bias* dos neurônios presentes na rede. O conjunto de estímulos do ambiente necessários para o treinamento de uma rede é chamado de conjunto de treinamento. O objetivo final do processo de treinamento é ajustar os parâmetros da rede de tal forma que a mesma possa, a partir de um estímulo não antes



apresentado, devolver uma saída coerente. Tal habilidade é chamada de generalização. Para isso, o conjunto de treinamento precisa ser escolhido de forma a ser representativo em relação aos estímulos que se pretende realizar inferências (HAYKIN, 2001). Durante o aprendizado, o conjunto de treinamento é apresentado diversas vezes à rede de forma que parâmetros sejam ajustados. A apresentação completa do conjunto de treinamento é chamada de época.

Dependendo do conjunto de treinamento disponível, o treinamento pode ser supervisionado ou não supervisionado. O treinamento supervisionado requer um conjunto de treinamento que consiste de um vetor de entrada e outro de saída. A rede utiliza o vetor de saída para guiar os ajustes dos parâmetros livres de forma a reduzir o erro entre a saída da rede e a saída desejada (ENGELBRECHT, 2007). Uma desvantagem do treinamento supervisionado é o fato de o tempo de treinamento crescer exponencialmente com o número de camadas da rede. (HAYKIN, 2001). Já no treinamento não supervisionado, o conjunto de treinamento é composto apenas do vetor de entrada. O objetivo de tal treinamento é descobrir padrões nos dados de entrada sem a presença dos dados de saída (HAYKIN, 2001).

### 3.3.1 Algoritmo de retropropagação (*backpropagation*)

Dentre os principais tipos de algoritmos de treinamento destaca-se o algoritmo de retropropagação do erro (*backpropagation*). Trata-se de um algoritmo de treinamento supervisionado utilizado em redes *feedforward* multicamada. Existem duas fases principais. Na primeira, as entradas são aplicadas a rede, produzindo um conjunto de saídas. Na segunda parte, baseado nos sinais de erro gerados na camada de saída, uma atualização dos parâmetros livres da rede é efetuada, partindo da última camada para a primeira. Como diversos outros, utiliza a minimização de uma função de custo para guiar os parâmetros livres dos neurônios. A função utilizada é a soma dos quadrados dos erros, mostrada na equação (8).

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (8)$$

Onde o conjunto  $C$  representa todos os neurônios da camada de saída da rede,  $n$  é a época (apresentação completa do conjunto de treinamento) atual do treinamento e  $e_j$  representa a diferença entre a saída

gerada pela rede e a saída esperada do conjunto de treinamento. A atualização dos parâmetros livres dos neurônios da camada de saída da rede é realizada através da equação (9) (peso  $w_{ji}$  é o peso que conecta a saída do neurônio  $i$  com a entrada do neurônio  $j$ ):

$$\Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}}{\partial w_{ji}}(n) = \eta \delta_j(n) y_i(n) \quad (9)$$

Onde  $\eta$  é uma constante positiva que determina a taxa de aprendizado,  $y_i(n)$  é a entrada referente ao peso  $w_{ji}$  no neurônio  $j$  e  $\delta_j(n)$  representa o gradiente local, que é o produto do sinal de erro do neurônio  $j$  da camada de saída pela derivada da função de ativação do neurônio, obtido através da equação (10). A figura 12 ilustra o fluxo do sinal para tal neurônio.

$$\delta_j(n) = e_j(n) \varphi'(v_j(n)) \quad (10)$$


Para o cálculo da atualização dos parâmetros em neurônios de camadas intermediárias, o processo é um pouco diferente. Para estes, o sinal de erro não está presente. Sendo assim, o gradiente local de um neurônio  $j$  em uma camada intermediária é calculado como a soma dos gradientes dos neurônios da camada seguinte, que estão conectados ao mesmo, ponderados pelos respectivos pesos. A equação (11) revela tal relação ( $D$  é o conjunto de todos os neurônios conectados ao neurônio  $j$  na camada seguinte):

$$\delta_j(n) = \varphi'(v_j(n)) \sum_{k \in D} \delta_k(n) w_{kj}(n) \quad (11)$$

Como a atualização dos parâmetros livres começa na camada de saída, os gradientes locais das camadas subsequentes sempre estarão disponíveis para o cálculo dos gradientes locais dos neurônios das camadas intermediárias.

As equações (10) e (11) deixam claro o motivo da função de ativação sigmoideal ser a mais utilizada em redes *feedforward* multicamada. Sendo uma função contínua e com derivadas suaves, a mesma é mais adequada para a aplicação.

Figura 12 - Fluxo de sinal para cálculo da atualização de peso em um neurônio da camada de saída



Fonte: Adaptado de Haykin (2001).

A atualização dos pesos pode ser feita de dois modos distintos (HAYKIN, 2001). No modo sequencial, os pesos são atualizados a cada apresentação de padrão de treinamento. Com um conjunto de treinamento com  $N$  padrões, serão realizadas  $N$  atualizações por época. Já no modo por lote, só é feita uma atualização por época. A atualização feita em cada peso é a média aritmética das atualizações calculadas para cada padrão de treinamento do conjunto. A função de custo também sofre mudanças neste segundo modo, passando a ser a média da equação (8) para todo o conjunto de treinamento, vide equação (12). O modo por lote requer mais armazenamento local para cada conexão sináptica, no entanto, diferentemente do modo sequencial, fornece uma convergência garantida para um mínimo local (HAYKIN, 2001).

$$\mathcal{E}_{med} = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n) \quad (12)$$

Como não existem parâmetros bem definidos para demonstrar que o algoritmo de retropropagação convergiu, alguns critérios razoáveis podem ser utilizados para encerrar o ajuste de pesos (HAYKIN, 2001). O critério mais simples é a estabilização da função de custo  $\mathcal{E}_{med}$ . Uma vez que a taxa de variação da mesma for suficientemente pequena, considerar-se-á que o algoritmo convergiu. Tal critério pode resultar, no entanto, em um encerramento prematuro do processo de aprendizagem.

Um segundo critério está relacionado com a superfície  $\mathcal{E}_{med}$  em função do vetor de pesos  $\mathbf{w}$ . Como o objetivo da convergência é obter um  $\mathcal{E}_{med}(\mathbf{w})$  mínimo, seja ele local ou global, é necessário que o vetor gradiente da superfície,  $g(\mathbf{w}) = \Delta \mathcal{E}_{med}(\mathbf{w})$ , seja igual a zero. Desta forma, um critério de parada muito usual para a convergência é estabelecer um limite mínimo a ser atingido pela norma euclidiana do vetor gradiente (KRAMER E VINCENTELLI, 1989), vide equação (13), sendo  $\epsilon$  o limite.

$$\|g(\mathbf{w})\| \leq \epsilon \quad (13)$$

### 3.3.2 Algoritmo Levenberg-Marquardt de retropropagação

O algoritmo Levenberg-Marquardt é uma combinação do algoritmo de retropropagação com o algoritmo de Gauss-Newton (YU e WILAMOWSKI, 2011). O mesmo herda a estabilidade do primeiro e a velocidade do segundo.

Apesar da popularidade do algoritmo de retropropagação, o mesmo é conhecido por sua convergência lenta. Devido a taxa de aprendizado constante, o algoritmo de retropropagação não leva em conta a intensidade do gradiente da função de erro. Utilizando as derivadas de segunda ordem da função de erro, o algoritmo Levenberg-Marquardt consegue avaliar a curvatura da mesma e obter um ajuste ponderado para os pesos de forma a obter uma convergência mais rápida (YU e WILAMOWSKI, 2011).

A ideia básica do algoritmo Levenberg-Marquardt é que o mesmo se comporte como o algoritmo de retropropagação padrão em regiões da curva de erro com curvatura complexa e quando a mesma se torna suave, o algoritmo de Gauss-Newton passa a atuar de forma a aumentar a velocidade de convergência (HAGAN e MENJAJ, 1994; YU e WILAMOWSKI, 2011).

## 3.4 ASPECTOS RELACIONADOS À CONFIABILIDADE DE REDES NEURAI

### 3.4.1 Natureza estatística do processo de treinamento


Uma rede neural é meramente uma forma pela qual conhecimento empírico sobre um fenômeno físico ou ambiente de interesse pode ser codificado através de treinamento (HAYKIN, 2001, p.110). Sendo assim, o objetivo do treinamento nada mais é do que guiar os parâmetros livres da rede através de uma regressão não-paramétrica que utiliza o conjunto

de treinamento para minimizar uma determinada função de custo. Tal regressão, no entanto, nunca será ótima, visto que o conjunto de treinamento nunca será grande o suficiente para representar o fenômeno em sua plenitude (HAYKIN, 2001).

Geman (1992) estabelece que o erro estimado entre a função ótima de regressão e a função obtida pelo treinamento pode ser dividido em duas parcelas: a parcela de bias e a parcela de variância. Enquanto a parcela de bias está relacionada à incapacidade da rede neural de aproximar com precisão a função de regressão, a parcela de variância representa a não-adequação da informação contida no conjunto de treinamento em relação ao fenômeno em questão (HAYKIN, 2001). Para que uma rede neural apresente um bom desempenho, é necessário que estas duas parcelas sejam pequenas. Infelizmente, constata-se que para um conjunto de treinamento de tamanho fixo, o preço para um bias pequeno é uma variância grande. Tal constatação é chamada de dilema bias/variância (GEMAN, 1992; HAYKIN, 2001).

A figura 13 ilustra o dilema em questão. O conjunto de treinamento, representado pelos quadrados no gráfico, foi obtido através da função  $g(x) = 4,26(e^{-x} - 4^{-2x} + 3e^{-3x})$ . Um ruído com distribuição normal, média zero e desvio padrão 0,2 foi adicionado aos dados. A figura 13a representa a respostas de uma rede neural com poucos neurônios na camada oculta. O tamanho reduzido da rede não permite que a mesma consiga realizar uma boa aproximação da função  $g(x)$ , gerando um elevado erro de bias, mas um pequeno erro de variância. Já na figura 13b, foi utilizada uma rede com um número elevado de neurônios na camada oculta. Tal arquitetura permite uma boa aproximação de  $g(x)$ , mas também faz com que a rede acabe aprendendo o ruído presente no conjunto de treinamento. Este comportamento é conhecido como *overfitting*. A capacidade de generalização da rede acaba sofrendo muito quando a parcela de variância é elevada. A resposta possui um pequeno erro de bias e um elevado erro de variância. A figura 13c representa uma situação em que foi utilizada uma rede de tamanho adequado, assim como uma estratégia de parada antecipada que será detalhada na seção 3.4.2. Percebe-se que tanto o erro de bias quanto o erro de variância são inferiores aos dos exemplos anteriores.

Figura 13 - Representação do dilema bias/variação



Legenda:

a – Treinamento com pequena variância e elevado bias;

b – Treinamento com pequeno bias e elevada variância;

c – Treinamento com equilíbrio entre bias e variância.

— Resultado da rede neural

- - - Função original dos dados de treinamento

Fonte: Adaptado de Geman (1992).


Para garantir que o treinamento leve em conta a capacidade de generalização, diferentes técnicas podem ser empregadas. Uma delas será discutida a seguir.

### 3.4.2 Validação cruzada

A validação cruzada é utilizada como um critério de parada adicional aos apresentados na seção 3.3.1. A mesma tem como objetivo auxiliar o algoritmo de treinamento a obter uma solução focada na capacidade de generalização. Para tal, o conjunto de dados presente é dividido em três subconjuntos: treinamento; validação e teste.

O subconjunto de treinamento continua sendo utilizado para guiar os parâmetros livres da rede, tal como retratado na seção 3.3. Entretanto, após cada época, é apresentado à rede o subconjunto de validação e o de teste, sendo o erro médio -- função de custo da equação (12) -- calculado para os mesmos. A figura 14 ilustra o funcionamento do critério. Enquanto o erro do subconjunto de treinamento permanece decaindo ao longo de todo o treinamento, após uma certa época, os erros dos subconjuntos de validação e teste começam a subir. Entende-se que após este ponto, o que a rede aprende é essencialmente o ruído contido nos padrões de treinamento (HAYKIN, 2001). Sendo assim, de forma a preservar a capacidade de generalização da rede, o ponto mínimo da curva de erro do subconjunto de validação é considerado como um critério sensato para encerrar o treinamento. Na figura 14, este ponto acontece na época de número 15. Por último, o subconjunto de teste é utilizado para avaliar a capacidade de generalização de rede, uma vez que o mesmo não influencia no treinamento.

Figura 14 - Método de parada antecipada através de validação cruzada



Fonte: Autor.

Como a curva de erro da validação pode, ao longo do treinamento, voltar a decair após um mínimo, é recomendável que se estabeleça um número de épocas a se esperar para garantir que tal erro não vá apresentar um valor inferior ao primeiro mínimo.

### 3.4.3 Máquinas de Comitê

Mesmo através de uma arquitetura otimizada e um conjunto de treinamento representativo, há casos em que apenas uma rede neural não é capaz de executar determinada tarefa com suficiente confiabilidade. Dentre os fatores limitadores, pode-se citar (CORAL, 2014; PAPADOPOULOS, 2001; PENZ, 2011):

- impossibilidade de verificar se o treinamento atingiu a um mínimo global para a função de erro;
- conjunto de treinamento finito não descreve o processo real por completo;
- ruído do conjunto de treinamento leva a uma solução não otimizada.

Para contornar tais limitações e aumentar a confiabilidade dos resultados obtidos por tais ferramentas, é comum a utilização de conjuntos de redes conhecidos como máquinas de comitê<sup>6</sup>. Um comitê é um grupo de redes neurais diferentes entre si sendo utilizadas em conjunto para obtenção de um resultado supostamente mais robusto (HAYKIN, 2001).

Para que o comitê consiga de fato melhorar a confiabilidade dos resultados, é necessário garantir uma certa diversidade entre as redes participantes. A mesma pode ser atingida, por exemplo, através do uso de diferentes arquiteturas, diferentes conjuntos de treinamento e inicialização aleatória dos parâmetros livres da rede no início do treinamento (NAFTALY, 1997).

A média aritmética é a forma mais simples de combinar as respostas de diversas redes de um comitê. Naftaly (1997) apresenta um estudo onde treina comitês de redes com apenas a inicialização dos parâmetros livres diferentes entre si. O mesmo constata de maneira analítica e experimental que a simples média aritmética das respostas já contribui para uma redução significativa da parcela do erro de variância, contribuindo para o aumento da confiabilidade da ferramenta.

---

<sup>6</sup> De forma a simplificar o texto, tais máquinas serão chamadas apenas de comitês de redes.



Penz (2011) realiza uma extensa pesquisa acerca dos trabalhos que abordam a utilização de comitês de redes nas mais diversas áreas (AHMAD, 2002; EDWARDS, 2002; FORTUNA, 2007; GRANITTO, 2005; HU e HWANG, 2002; TRICHAKIS, 2011; WU, 2010; YU, 2009; ZIO, 2006). Os trabalhos expõem diversas metodologias para a otimização de tais comitês, como a filtragem de redes para a composição dos resultados, e reforçam a necessidade da independência das redes para a composição de um comitê robusto.


De acordo com a literatura, um método bastante utilizado para a formação de comitês de redes neurais é o *bootstrap*. Trata-se de um método de simulação para inferência do intervalo de confiança de um determinado parâmetro estatístico (EFRON e TIBSHIRANI, 1993). Quando aplicado no contexto de redes neurais artificiais, o método se resume a criação de um comitê de redes cujos conjuntos de treinamento são obtidos através de amostragem com reposição do conjunto de dados disponível (PAPADOPOULOS, 2001). A incerteza referente aos dados de treinamento é então obtida pela variância dos resultados das redes do comitê, permitindo uma estimativa da incerteza relativa ao uso das RNA (PENZ, 2011).

### 3.5 INSERÇÃO DE CARACTERÍSTICAS DINÂMICAS EM MODELOS ESTÁTICOS DE REDES NEURAIIS

O algoritmo de retropropagação é o método mais popular para treinamento de redes neurais. No entanto, o mesmo só é capaz de treinar redes em que a relação entre as entradas e saídas é estática, ou seja, tal relação não apresenta variação temporal. Em casos onde a saída da rede não depende apenas do valor atual da entrada, mas também dos valores anteriores, tal algoritmo não seria capaz de modelar corretamente a relação. No entanto, em casos onde a variação temporal entre as entradas e saídas da rede é estacionária – quando seus parâmetros estatísticos não se alteram com o tempo (HAYKIN, 2001) – alterações podem ser feitas na arquitetura da rede para adicionar uma certa característica dinâmica ao modelo.

Em casos de variação temporal estacionária, uma alteração possível é a inserção de linhas de atraso, onde valores de entrada anteriores da série temporal são utilizados como entradas da rede. Desta forma cada conjunto de entrada possui uma certa memória da série temporal. A representação de tal estratégia é apresentada na figura 15.

Figura 15 - Representação de arquitetura de rede neural com linhas de atraso



Legenda:

$n$  = tempo atual;

$n-x$  = tempo atual menos  $x$ .

Fonte: Autor.

Essa estratégia é recomendada principalmente quando o propósito da rede neural é o prognóstico do comportamento da entrada em um tempo futuro. Como exemplo, se a saída  $y(n)$  da figura 15, fosse na verdade o valor  $x(n+1)$ , ou seja, a previsão do próximo valor de  $x$ . A utilização desta técnica, assim como as diversas outras apresentadas nesse capítulo, será apresentada no próximo capítulo, onde as ferramentas para a inferência do ponto de entrada em regime permanente e prognóstico do valor final serão detalhadas e analisadas.

## 4 SISTEMA NEURAL PARA INFERÊNCIA DA ENTRADA EM REGIME E PROGNÓSTICO DO VALOR FINAL

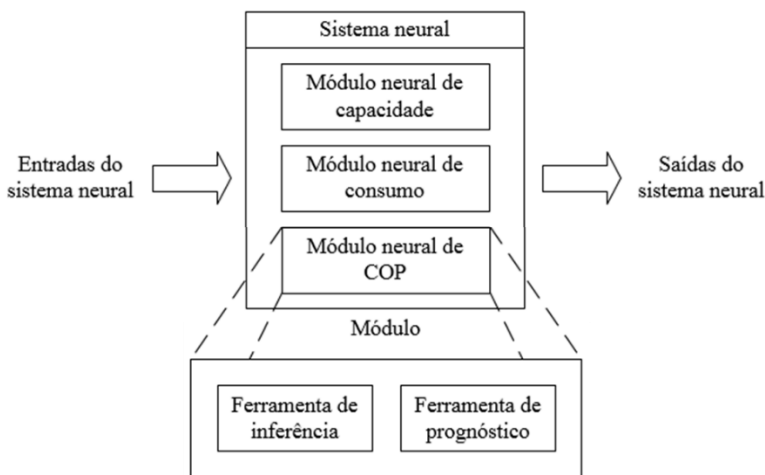
### 4.1 PANORAMA

As ferramentas utilizadas durante este trabalho são o resultado de exaustivas tentativas de aprimoramento e adequação das mesmas, realizadas em trabalhos anteriores, às tarefas de inferência do ponto de entrada dos parâmetros de desempenho em regime permanente e prognóstico do valor final de tais parâmetros.

Os primeiros trabalhos desenvolvidos por Henklein (2006) e Steinbach (2008) geraram uma base de conhecimento utilizada por Lima (2010b) para a criação de uma arquitetura com desempenho satisfatório para a aplicação.

Lima (2010b) desenvolveu um sistema neural composto de módulos para cada parâmetro de desempenho. Cada módulo, por sua vez, é composto de duas redes neurais: a rede de inferência da entrada em regime permanente e a rede de prognóstico do valor final do parâmetro. Como a complexidade das tarefas é diferente, tais redes possuem arquiteturas distintas. Uma representação deste sistema é apresentada na figura 16.

Figura 16 - Sistema neural desenvolvido por Lima (2010b)



Fonte: Adaptado de Lima (2010b).

Na busca por uma maior confiabilidade dos resultados apresentados pelas ferramentas de Lima (2010b), Penz (2011) passou a utilizar comitês de redes neurais aliados ao método *bootstrap* para a execução de cada tarefa dentro dos módulos neurais. Tal análise, no entanto, ficou limitada ao parâmetro capacidade de refrigeração, sendo que o autor possuía apenas 61 ensaios para o treinamento do comitê e 275 ensaios para a análise do desempenho das ferramentas.

Neste trabalho, uma biblioteca com mais de 1000 ensaios de desempenho de compressores herméticos foi disponibilizada para análise do desempenho das ferramentas desenvolvidas por Lima (2010b) aliadas as estratégias de aumento de confiabilidade desenvolvidas por Penz (2011). Os três parâmetros de desempenho foram contemplados: capacidade de refrigeração, consumo e COP.

Tendo em vista que o método de medição A, apresentado na seção 2.3.1, é o mais comumente utilizado para o cálculo da capacidade de refrigeração<sup>7</sup>, o mesmo foi utilizado em detrimento do método F, utilizado nos trabalhos anteriores. A diferença entre suas dinâmicas, apresentada na figura 6, tem impacto no aprendizado das redes e foi levada em consideração quando da seleção dos parâmetros de rede.

Ao longo deste capítulo, serão detalhadas as ferramentas utilizadas neste trabalho, assim como os métodos empregados para obtenção das mesmas. Para facilitar o entendimento, será detalhada primeiramente a ferramenta para inferência do regime permanente dos parâmetros de desempenho, seguida da ferramenta para o prognóstico do valor final de tais parâmetros. Cada ferramenta é composta por um comitê de redes neurais aliados a um conjunto de regras para a integração das respostas das redes. Logo após, será apresentada a análise realizada na biblioteca de ensaios disponibilizada para o treinamento e teste das ferramentas. Por último, o processo de treinamento e teste dos comitês de redes será apresentado junto com alguns resultados.

## 4.2 FERRAMENTA PARA INFERÊNCIA DA ENTRADA EM REGIME PERMANENTE

Como já explicado na seção 2.4, o regime permanente é alcançado quando as flutuações de um certo grupo de variáveis controladas permanecerem dentro de limites preestabelecidos. Tais limites são expressos em porcentagem do valor lido. Devido à forma como as normas descrevem o cálculo dos parâmetros de desempenho – calculados como


---

<sup>7</sup> Tal informação é confirmada pela biblioteca de ensaios disponibilizada.

sendo a média aritmética das medidas da última hora de ensaio – constata-se que o instante de entrada real em regime só é conhecido ao final do ensaio (ISO 917, 1989; PENZ, 2011).

As ferramentas desenvolvidas pelo grupo de pesquisa em trabalhos anteriores (LIMA, 2010b; PENZ, 2011) contornam as limitações citadas através da análise do comportamento das variáveis durante o ensaio e sua correlação com a chegada ao regime permanente. Idealmente, as mesmas deveriam identificar o ponto exato onde ocorre a transição do regime transitório para o permanente. A figura 17 apresenta tal transição. Após 75 minutos, percebe-se que a capacidade permanece dentro do limite de  $\pm 2\%$  do valor final de ensaio, descrito na seção 2.4. A ferramenta ideal indicaria a chegada ao regime permanente neste momento.

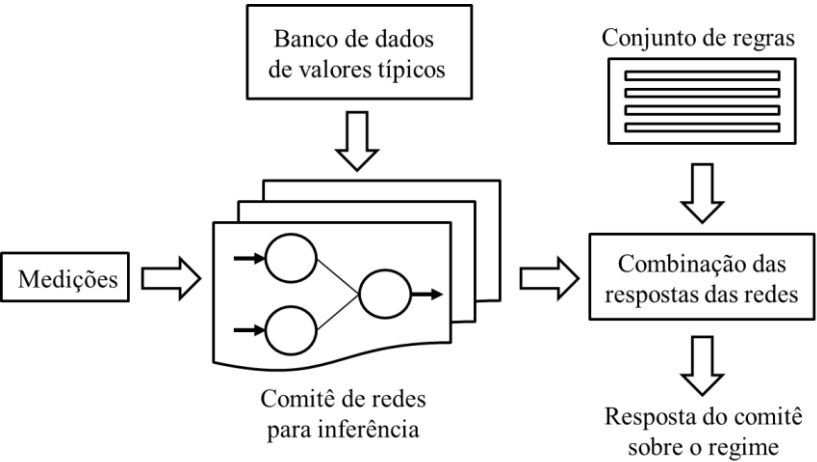
Figura 17 - Transição do regime transitório para o permanente em ensaio da capacidade de refrigeração



Fonte: Adaptado de Penz (2011).

A ferramenta desenvolvida para realizar a tarefa de inferência de entrada em regime permanente dos parâmetros de desempenho teve como base a arquitetura de rede neural desenvolvida por Lima (2010b) aliada ao uso de comitês de redes. Além disso, a ferramenta ainda utiliza um banco de dados de valores típicos dos parâmetros de desempenho - e outras variáveis medidas durante o ensaio - e um conjunto de regras para combinar as respostas do comitê de redes, ambos propostos por Penz (2011). A forma de obtenção de tal conjunto de regras será apresentada ao longo deste capítulo. A figura 18 apresenta o esquema geral da ferramenta.

Figura 18 - Esquema geral da ferramenta para inferência do regime permanente dos parâmetros de desempenho



Fonte: Adaptado de Penz (2011).

4.2.1 Arquitetura da rede e algoritmo de treinamento

A arquitetura utilizada para a tarefa de inferência do momento de entrada em regime permanente foi uma rede do tipo *feedforward* multicamada. A mesma configuração foi utilizada para os três parâmetros de desempenho. O quadro 1 expõe a configuração da rede.

Quadro 1 - Arquitetura da rede neural para inferência do regime permanente

Camada	Número de neurônios	Função de ativação
Entrada	16	-
1ª escondida	15	Tangente hiperbólica
2ª escondida	10	Tangente hiperbólica
3ª escondida	10	Tangente hiperbólica
Saída	1	Logística

Fonte: Autor.

O tipo de treinamento foi supervisionado e o algoritmo utilizado para a atualização dos parâmetros livres foi o Levenberg-Marquardt. Todo o processo de treinamento foi realizado no software *Matlab*, que conta com uma toolbox específica para aplicações de redes neurais

(MATHWORKS, 2007). Ao todo, foram utilizados quatro critérios de parada: número máximo de épocas, performance desejada atingida, gradiente mínimo atingido e validação cruzada. No primeiro, o algoritmo encerra caso atinja um determinado número de épocas. No segundo, o algoritmo encerra se o erro quadrado médio atingir um valor de performance arbitrado. No terceiro, o algoritmo encerra caso a norma euclidiana do vetor gradiente da superfície de erro tenha atingido um valor mínimo. No quarto, o algoritmo encerra caso um determinado número de épocas tenha passado sem que o erro médio quadrado do conjunto de validação tenha sofrido redução. Os valores arbitrados para cada critério de parada são expostos no quadro 2. Devido a processos de tratamento dos dados de entrada da rede, alguns dos parâmetros são adimensionais.

Quadro 2 - Valores arbitrados para os critérios de parada da rede de inferência

<i>Critério de parada</i>	<i>Valor arbitrado</i>
Número máximo de épocas	1500 épocas
Performance	0,0011
Gradiente	0,001
Número de épocas de validação	100 épocas

Fonte: Autor.

#### 4.2.2 Variáveis de entrada

A rede para inferência da entrada em regime permanente utiliza basicamente as medições de três variáveis obtidas no ensaio de desempenho energético. A primeira é o parâmetro de desempenho, que pode ser a capacidade de refrigeração, o consumo ou o COP, dependendo do módulo neural. As outras duas são iguais para todos os módulos. São elas: a temperatura da carcaça do compressor e a pressão de sucção, medida logo antes da entrada do compressor. Tais variáveis são tratadas para compor as 16 entradas apresentadas no quadro 3. A utilização de médias deslocadas, assim como das diferenças entre as mesmas, está relacionada com a limitação de processamento da arquitetura selecionada. Como explicado na seção 3.5, redes *feedforward* multicamada, treinadas com o algoritmo de retropropagação, são capazes apenas de modelar sistemas estáticos. As mesmas são capazes de classificar padrões, contanto que os mesmos não sejam dependentes do tempo. Quando a classificação não depende apenas do valor presente da entrada, mas também de seus valores passados, o sistema é classificado como dinâmico (HAYKIN, 2001). Para permitir que a rede seja capaz de modelar

sistemas dinâmicos, são adicionadas médias deslocadas, assim como diferenças entre tais médias, das três variáveis de entrada. Dessa forma todo conjunto de entrada da rede apresentará uma certa memória do comportamento das três variáveis em relação ao tempo.

Quadro 3 - Entradas da rede de inferência da entrada em regime permanente dos parâmetros de desempenho

Variável	Entrada	
Parâmetro de desempenho (CAP, CONS ou COP)	1	Desvio padrão de 15 amostras da variável precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Diferença entre 2ª e 3ª entrada (D1).
	6	Diferença entre 3ª e 4ª entrada (D2).
	7	Diferença entre 2ª e 4ª entrada (D3).
	8	Diferença entre 5ª e 6ª entrada (D4).
Temperatura da carcaça do compressor	9	Média de 15 amostras da variável precedentes ao instante atual.
	10	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	11	Diferença entre 9ª e 10ª entrada.
	12	Diferença entre a 9ª entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.
Pressão de sucção	13	Média de 15 amostras da variável precedentes ao instante atual.
	14	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	15	Diferença entre 13ª e 14ª entrada.
	16	Diferença entre a 13ª entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.


Fonte: Autor.

A representação das oito primeiras entradas é apresentada na figura 19. Considerando o instante atual como sendo 37,8 minutos, é possível



verificar os conjuntos de amostras que serão utilizadas para formar as médias das entradas dois a quatro e, através destas, as diferenças das entradas cinco a oito.

Figura 19 - Representação das entradas relacionadas ao parâmetro de desempenho



Fonte: Adaptado de Lima (2010b).

### 4.2.3 Pré-processamento das variáveis de entrada

Antes de serem utilizadas pela rede, as variáveis de entrada precisam passar por etapas de pré-processamento. Estas etapas têm como objetivo melhorar o desempenho do algoritmo de treinamento. A seguir, serão detalhadas as três etapas utilizadas.

#### a) Equalização das variáveis de entrada

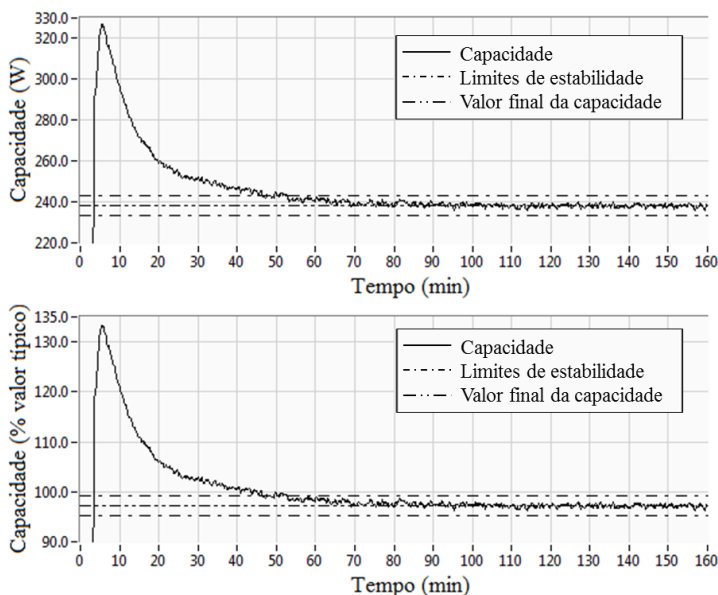
Dentre os ensaios presentes na biblioteca, existem compressores das mais variadas capacidades. Em relação a capacidade de refrigeração, o fabricante divide os ensaios de compressores da seguinte forma (PENZ, 2011):

- Alta capacidade – 175 W a 265 W;
- Média capacidade – 100 W a 175 W;
- Baixa capacidade – até 100 W.

De forma a evitar que a rede neural fique sensível à classificação do compressor de acordo com sua capacidade final, as três variáveis de

entrada da rede são divididas pelo valor típico esperado para o determinado conjunto modelo/condição de ensaio. Um modelo de compressor pode apresentar diferentes valores típicos para seus parâmetros de desempenho dependendo da condição de teste a qual ele é exposto durante o ensaio. Dessa forma, uma condição típica é definida tanto pelo modelo em teste quanto pelas condições de ensaio. Sendo assim, um banco de dados de valores típicos dos parâmetros de desempenho e das outras variáveis de entrada da rede foi levantado de forma a permitir a equalização dos mesmos. Os valores típicos dos parâmetros de desempenho foram obtidos através das fichas técnicas dos modelos presentes no conjunto de ensaios. Os valores típicos para a temperatura da carcaça do compressor e para a pressão de sucção foram retirados da própria biblioteca de ensaios disponível. Após a equalização, as variáveis de entrada passam a ser expressas pela porcentagem do seu valor típico. A figura 20 apresenta a curva de um ensaio de capacidade de refrigeração antes e após a equalização. É somente após a realização desta etapa que as três variáveis são divididas nas 16 entradas apresentadas no quadro 3.

Figura 20 - Capacidade de refrigeração antes e após equalização

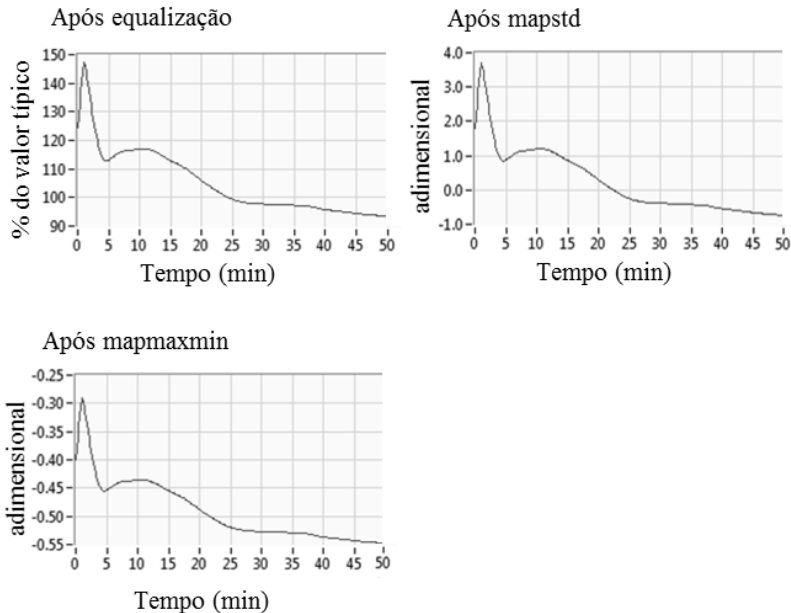


Fonte: Autor.

## b) Normalização das variáveis

Segundo Haykin (2001), as variáveis de entrada da rede devem ser normalizadas de forma que o valor médio, calculado sobre todo o conjunto de treinamento, seja próximo de zero ou pelo menos pequeno comparado ao desvio padrão (HAYKIN, 2001, p. 208). Tal medida tem como objetivo a aceleração do processo de treinamento. Para garantir isso, duas funções da toolbox de redes neurais do *Matlab* foram utilizadas (MATHWORKS, 2007). A primeira, *mapstd*, transforma o conjunto de treinamento de cada uma das entradas em uma distribuição com média 0 e desvio padrão 1. A segunda, *mapminmax*, limita os valores de entrada ao intervalo  $[-1,1]$  dependendo dos valores máximos e mínimos do conjunto de treinamento. A utilização destas duas etapas foi primeiramente utilizada em Lima (2010b). O efeito de cada função pode ser observado na figura 21. Esta etapa é realizada após a formação das 16 entradas da rede. Sendo assim, a normalização é realizada para cada uma das entradas.

Figura 21 - Efeito das funções de normalização em uma entrada da rede neural




Fonte: Autor.

### c) Limitação do intervalo de ensaio

É comum que no início do ensaio de desempenho energético, as variáveis medidas apresentem variações de amplitude elevadas devido aos ajustes do controle. Sendo assim, para o treinamento das redes neurais, as primeiras 30 amostras (5 min) são sempre descartadas. Para padronizar o tamanho dos ensaios de treinamento, o instante final do intervalo corresponde ao menor tempo de ensaio dentre todos os ensaios de treinamento. O intervalo em questão pode ser observado na figura 22.

Figura 22 - Intervalo de ensaio utilizado para o treinamento




Fonte: Autor.

## 4.2.4 Saída da rede

O neurônio de saída da rede neural para inferência da entrada em regime permanente dos parâmetros de desempenho apresenta uma função de ativação do tipo logística (fig. 9). Sendo assim, a saída pode retornar valores entre 0 e 1. Em uma ferramenta ideal, a saída permaneceria indicando 0 até o momento de entrada no regime permanente, onde passaria a indicar o nível 1. O que se vê na realidade é um aumento do valor de saída à medida que o regime permanente se aproxima. A figura 23 apresenta o comportamento da saída de uma rede neural treinada para inferir a entrada em regime permanente da capacidade de refrigeração. Como a resposta da rede tende assintoticamente ao valor 1, é razoável arbitrar um valor inferior como sendo o limiar entre o regime transitório e o permanente. Tal limiar recebe o nome de patamar de decisão. Em

trabalhos anteriores utilizando esta arquitetura (LIMA, 2010b; PENZ, 2011), tal valor foi arbitrado como sendo 0,7 para a capacidade de refrigeração e COP e 0,9 para o consumo. Neste trabalho, foi realizado um novo estudo para verificar tais valores.

Figura 23 - Exemplo de saída da rede neural em relação a um ensaio de capacidade de refrigeração




Fonte: Autor.

#### 4.2.5 Estratégias para minimizar erro de falso positivo

O ensaio apresentado na figura 23 é um exemplo de ensaio bem-comportado. A capacidade se eleva até um certo ponto e em seguida passa a sofrer uma queda comportada até a estabilização. No entanto, existem ensaios onde o parâmetro de desempenho começa a apresentar sinais de estabilização, mas em seguida volta a variar o sinal de forma significativa. Um exemplo deste tipo de ensaio é apresentado na figura 24. Após 40 minutos, o mesmo aparenta atingir a estabilização, no entanto, aos 60 minutos, o sinal sofre uma queda e volta a estabilizar em 100 minutos. Tal comportamento influencia diretamente na resposta da rede, apresentada na figura 24. Ao perceber a primeira estabilização, o sinal de saída apresenta uma elevação aos 30 minutos e permanece em alta até 60 minutos, quando volta a decair. Este comportamento de estabilização momentânea não é tão incomum nos ensaios de parâmetros de

desempenho, sendo extremamente prejudicial para a inferência da entrada em regime permanente. É observado ainda uma elevação aos 10 minutos de ensaio, provavelmente decorrente da instabilidade das variáveis de entrada da rede no início do ensaio.

Figura 24 - Saída da rede neural para um ensaio de capacidade de refrigeração com estabilização momentânea



Fonte: Autor.

Para evitar que as redes de inferência avaliem as situações supracitadas como estabilizadas, duas estratégias adicionais foram utilizadas. A primeira estabelece um tempo mínimo de ensaio para que a inferência possa acontecer. Após vários testes, foi arbitrado o valor de 800 segundos (13,3 minutos) como o tempo mínimo para que a rede possa inferir a entrada em regime permanente dos parâmetros de desempenho. A partir de tal ponto, entende-se que as variáveis de entrada já não apresentam mais instabilidades e a ferramenta de inferência pode ser utilizada.

A segunda estratégia está relacionada a um tempo mínimo acima do patamar de decisão para inferir o regime. Dessa forma, foi estabelecido que somente após indicação contínua acima do patamar de decisão por 400 segundos (6,6 minutos), a inferência de entrada em regime permanente é validada. Tal valor foi definido em função do tempo médio

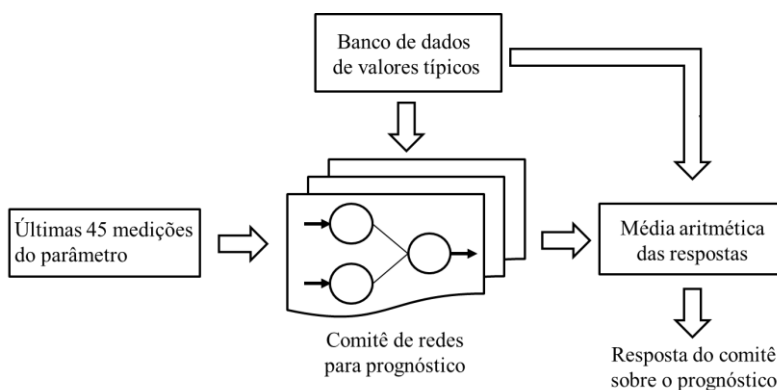
que ensaios com estabilização momentânea permanecem estabilizados antes de voltarem a variar o sinal. Valores maiores que esse, permitiriam uma maior confiança no resultado, mas aumentariam ainda mais o tempo necessário para a inferência.

A partir destas duas estratégias, o erro de falso positivo gerado por ensaios com estabilização momentânea foi reduzido consideravelmente, mas para casos extremos como o da figura 24, tal erro ainda persiste.

#### 4.3 FERRAMENTA PARA PROGNÓSTICO DO VALOR FINAL DE ENSAIO

Uma vez obtida a inferência da entrada em regime permanente, a ferramenta de prognóstico utiliza os dados já obtidos para realizar uma previsão do valor final do parâmetro de desempenho. A figura 25 apresenta o esquema geral da ferramenta. Como pode ser visto, o esquema é semelhante ao aplicado para a tarefa de inferência da chegada ao regime permanente, utilizando um comitê de redes neurais e um banco de dados de valores típicos. A forma como as respostas das diversas redes do comitê é combinada, no entanto, é mais simples, sendo uma média aritmética dos resultados. Novamente, a arquitetura de rede neural utilizada para o prognóstico foi a mesma desenvolvida por Lima (2010b) para a mesma função.

Figura 25 - Esquema geral da ferramenta para o prognóstico do valor final dos parâmetros de desempenho



Fonte: Adaptado de Penz (2011).

Ao contrário da ferramenta para inferência, a qual infere se o ensaio está em regime permanente a cada nova amostra, a ferramenta de prognóstico é utilizada apenas uma vez, sendo que todos os dados necessários para a realização do prognóstico estão disponíveis no momento da inferência do regime.

### 4.3.1 Arquitetura da rede e algoritmo de treinamento

A arquitetura utilizada para o prognóstico dos três parâmetros de desempenho foi uma rede do tipo *feedforward* multicamada. O quadro 4 expõe a configuração da rede.

Quadro 4 - Arquitetura da rede neural para o prognóstico do valor final

<i>Camada</i>	<i>Número de neurônios</i>	<i>Função de ativação</i>
Entrada	8	-
1ª escondida	20	Tangente hiperbólica
Saída	1	Linear

Fonte: Autor.

Novamente, o tipo de treinamento foi supervisionado e o algoritmo utilizado para a atualização dos parâmetros livres foi o Levenberg-Marquardt. Os mesmos critérios de parada foram utilizados: número máximo de épocas, performance desejada atingida, gradiente mínimo atingido e validação cruzada. Os valores arbitrados para cada critério de parada são expostos no quadro 5.

Quadro 5 - Valores arbitrados para os critérios de parada da rede de prognóstico

<i>Critério de parada</i>	<i>Valor arbitrado</i>
Número máximo de épocas	10000 épocas
Performance	0,01
Gradiente	$10^{-6}$
Número de épocas de validação	100 épocas

Fonte: Autor.

### 4.3.2 Variáveis de entrada

A rede de prognóstico do valor final dos parâmetros de desempenho utilizada apenas as medições do próprio parâmetro para



realizar a previsão, vide quadro 6. Tais entradas foram representadas na figura 19.

Quadro 6 - Entradas da rede de prognóstico do valor final dos parâmetros de desempenho


Variável	Entrada	
Parâmetro de desempenho (CAP, CONS ou COP)	1	Desvio padrão de 15 amostras da variável precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Diferença entre 2ª e 3ª entrada (D1).
	6	Diferença entre 3ª e 4ª entrada (D2).
	7	Diferença entre 2ª e 4ª entrada (D3).
	8	Diferença entre 5ª e 6ª entrada (D4).

Fonte: Autor.

### 4.3.3 Pré-processamento das variáveis de entrada

Assim como na rede de inferência, as entradas da rede de prognóstico também passam pelo processo de equalização e normalização. A única diferença nesse aspecto é o intervalo de ensaio utilizado durante o treinamento. Para a rede de prognóstico, o intervalo inicia na entrada real em regime permanente e finaliza no menor tempo de ensaio dentre todos os ensaios de treinamento. O intervalo em questão pode ser observado na figura 26.

Figura 26 - Intervalo de ensaio utilizado para o treinamento da rede de prognóstico



Fonte: Autor.

#### 4.3.4 Saída da rede


Da mesma forma que as entradas da rede são equalizadas e normalizadas antes de serem apresentadas para o treinamento, as saídas que serão utilizadas como as guias para o processo de aprendizado também passam por um processo de equalização. Desta forma, a saída da rede neural de prognóstico retorna uma porcentagem que deve ser multiplicada pelo valor típico do conjunto modelo/condição para a obtenção do prognóstico do valor final de ensaio.

#### 4.4 ANÁLISE DA BIBLIOTECA DE ENSAIOS

O conjunto de ensaios disponibilizado para este trabalho contém um total de 3034 ensaios de desempenho. No entanto, uma grande quantidade não pôde ser aproveitada para utilização no sistema neural. Dentre os motivos que levaram à eliminação de parte do conjunto estão a falta de dados necessários para a utilização na rede, como o modelo de compressor ou a condição de ensaio, e a presença de anomalias nos sinais, provavelmente oriundas de uma alteração nos parâmetros de controle da bancada durante a realização dos ensaios. Um exemplo deste último caso é apresentado na figura 27. Aos 40 minutos, o ensaio apresenta uma clara indicação de estabilização, mas logo em seguida ocorre uma variação

brusca, levando a estabilização<sup>8</sup> a ocorrer somente aos 80 minutos de ensaio.

Figura 27 - Ensaio com anomalia no sinal de capacidade de refrigeração



Fonte: Autor.

Através das limitações estabelecidas, foram selecionados 1117 ensaios capazes de serem utilizados para o treinamento e teste do sistema neural. Dentro deste conjunto estão presentes ensaios de 46 modelos diferentes de compressores testados em 27 condições diferentes, totalizando 87 combinações modelo/condição. Cada condição indica as temperaturas de evaporação e condensação do ensaio. O conjunto apresenta modelos que utilizam fluido refrigerante R-600a e R-134a.

O quadro 7 apresenta como está distribuído o conjunto selecionado em relação a capacidade e ao fluido refrigerante.

Quadro 7 - Divisão do conjunto selecionado por capacidade e fluido refrigerante

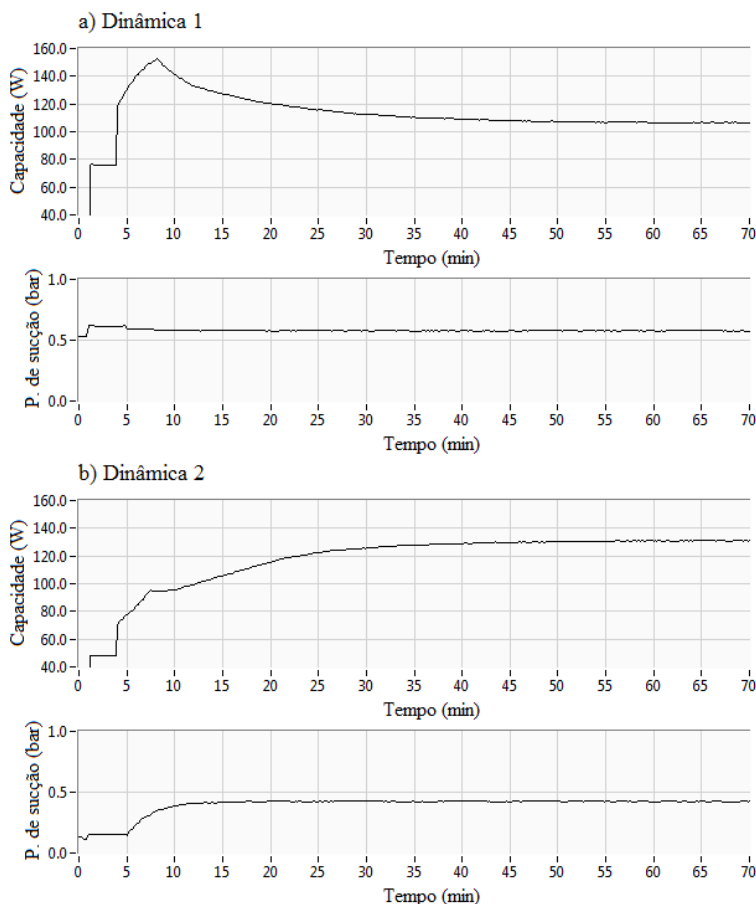
Capacidade	Quantidade
Baixa	67
Média	153
Alta	897
Fluido Refrigerante	Quantidade
R-600a	270
R-134a	847

Fonte: Autor.

<sup>8</sup> Conforme seção 2.4, estabilização é atingida quando o sinal de capacidade adentra a faixa de  $\pm 2\%$  do valor final.

Durante a análise foram detectadas duas dinâmicas distintas nos ensaios de capacidade de refrigeração obtidos através do método A. As mesmas são apresentadas na figura 28.

Figura 28 - Dinâmicas da capacidade de refrigeração obtida pelo método A



Fonte: Autor.

Para 88% (986) dos ensaios, o sinal apresenta uma sobre-elevação, adentrando a zona de estabilização pelo limite superior. Tal dinâmica foi identificada de Dinâmica 1. Já para os 12% (131) restantes, o sinal adentra a zona de estabilização pelo limite inferior. Para essa segunda, foi dado o nome de Dinâmica 2. Ao observar a dinâmica da pressão de sucção nos

dois ensaios da figura 28, constata-se uma correlação desta com a dinâmica da capacidade. Dinâmicas similares também foram observadas nos sinais de COP, uma vez que o mesmo é resultado da divisão do sinal de capacidade pelo de consumo. Para o sinal de consumo, não há uma diferença acentuada entre dinâmicas.

Uma vez que as ferramentas para inferência do regime permanente e prognóstico do valor final de ensaio utilizam entradas ligadas ao comportamento da dinâmica dos parâmetros de desempenho, é importante que todos os tipos de dinâmica relevantes estejam bem representados nos conjuntos de treinamento, validação e teste.

#### 4.5 FORMAÇÃO DOS CONJUNTOS DE TREINAMENTO, VALIDAÇÃO E TESTE

Para criação dos conjuntos de treinamento e validação buscou-se criar um equilíbrio entre as diversas capacidades de compressor e dinâmicas presentes no conjunto de 1117 ensaios disponíveis. Foi selecionado um conjunto de 275 ensaios para cada parâmetro, sendo os mesmos diferentes entre si. Para os parâmetros de capacidade e COP, o conjunto foi dividido em quatro subconjuntos, como pode ser visto no quadro 8. Os três primeiros são referentes a ensaios da Dinâmica 1 divididos pelas faixas de capacidade. Como indicado no quadro 7, a divisão dos ensaios disponíveis por faixa é bem desequilibrada. Sendo assim, a maior parte dos ensaios selecionados é de alta capacidade. O quarto subconjunto diz respeito a ensaios que apresentam a Dinâmica 2. Dentro deste subconjunto existem ensaios de todas as faixas de capacidade.

Quadro 8 - Divisão dos conjuntos de treinamento e validação

Subconjuntos	Parâmetro de desempenho		
	Capacidade	COP	Consumo
Dinâmica 1 – Baixa CAP	25	25	25
Dinâmica 1 – Média CAP	50	50	50
Dinâmica 1 – Alta CAP	150	150	200
Dinâmica 2	50	50	-
<b>Total de ensaios</b>	<b>275</b>	<b>275</b>	<b>275</b>


Fonte: Autor.

Para o consumo, o conjunto foi dividido em 3 subconjuntos com ensaios de capacidades diferentes, uma vez que não há a diferença de dinâmicas presente nos ensaios de capacidade e COP.


Para cada rede treinada, são selecionados 100 ensaios dentro do conjunto de 275. De cada subconjunto, é extraída uma quantidade fixa de ensaios de forma aleatória e sem reposição. Tal método é similar ao método *bootstrap*, descrito na seção 3.5.3, entretanto, esse último apresenta reposição dos ensaios. Embora a ausência de reposição diminua a quantidade de diferentes conjuntos de treinamento possíveis, a mesma permite que uma quantidade maior de ensaios sejam utilizadas no treinamento e validação de cada rede. Dos 100 ensaios selecionados, 88 são utilizados para o treinamento e os outros 12 para validação. A quantidade de ensaios retirados de cada subconjunto, assim como a divisão entre os ensaios de treinamento e validação, é apresentada na figura 29.

Figura 29 - Obtenção do conjunto de ensaios para treinamento e validação das redes neurais

a) Seleção para capacidade e COP



b) Seleção para consumo



Fonte: Autor.

Os ensaios restantes são utilizados no conjunto de teste. Para os parâmetros capacidade e COP, tal conjunto possui 842 ensaios. Para o consumo, o mesmo tem 840.

## 4.6 COMITÊS DE REDES NEURAIS PARA INFERÊNCIA DE ENTRADA EM REGIME PERMANENTE

Definidas as arquiteturas de rede, os parâmetros de treinamento e os conjuntos de treinamento, validação e teste, teve início o processo de treinamento dos comitês de redes neurais. Todo o processo de treinamento das redes foi realizado em software *Matlab* com auxílio da *neural networks toolbox* (MATHWORKS, 2007). Um programa em software *Labview* foi criado para avaliar as redes treinadas em relação aos conjuntos de teste.

Para realizar a inferência da entrada em regime permanente da capacidade de refrigeração, Penz (2011) utilizou um comitê composto por 30 redes neurais. Neste estudo, devido a diversidade de modelos de compressores e condições de ensaio presentes nos conjuntos de treinamento e teste, optou-se por treinar comitês de 120 redes neurais para a tarefa de inferência da entrada em regime permanente dos parâmetros de interesse. Tal número se mostrou capaz de garantir a confiabilidade necessária para a aplicação neste trabalho. No entanto, é possível que um subconjunto de redes desses comitês fosse o suficiente para obter o mesmo resultado.

### 4.6.1 Comitê para inferência da entrada em regime permanente da capacidade de refrigeração

Existem três possibilidades para a resposta de uma rede de inferência de entrada em regime permanente. Na primeira, a inferência ocorre após a entrada em regime real, gerando um erro de falso negativo (FN). Na segunda, a inferência ocorre antes da entrada em regime, gerando um erro de falso positivo (FP). Na terceira, a rede não é capaz de inferir a entrada em regime. Do ponto de vista de confiabilidade das respostas, o erro de falso positivo é mais danoso do que o de falso negativo. Após a inferência, o comitê de prognóstico utiliza os últimos dados recebidos para prever o valor final do ensaio. Caso o regime ainda não tenha sido atingido, o comitê de prognóstico receberá dados do regime transiente. Como apenas dados do regime permanente são utilizados durante o treinamento deste comitê (figura 26), a apresentação de dados fora desta faixa prejudica a capacidade das redes de retornar uma resposta confiável. Sendo assim, redes mais conservadoras<sup>9</sup>, apesar de


---

<sup>9</sup> Que apresentam uma menor probabilidade de erro de falso positivo.

demorarem mais tempo para realizar a inferência, são mais recomendadas para a aplicação.

O primeiro comitê treinado foi o comitê de inferência da entrada em regime permanente da capacidade de refrigeração. Para decidir o patamar de decisão da saída das redes neurais foi utilizado o conjunto de teste. Para cada patamar testado, os 842 ensaios do conjunto de teste foram apresentados às 120 redes do comitê, gerando mais de 100 mil inferências. O resultado pode ser visto nos gráficos da figura 30. No primeiro gráfico é possível verificar a porcentagem dos ensaios de teste onde a inferência foi realizada após a entrada em regime real (com FN), a porcentagem de ensaios onde a inferência foi realizada antes da entrada em regime real (com FP) e a porcentagem de ensaios onde não foi possível obter inferência para cada patamar testado. Quanto maior o patamar de decisão, menor a quantidade de inferências com erro de falso positivo, mas também é maior a quantidade de ensaios sem inferência. Já no segundo gráfico, é possível verificar o aumento do tempo médio das inferências em relação ao tempo médio de entrada em regime permanente do conjunto de teste.

Figura 30 - Comportamento do comitê de redes de inferência da capacidade de refrigeração para diferentes patamares de decisão



Fonte: Autor.

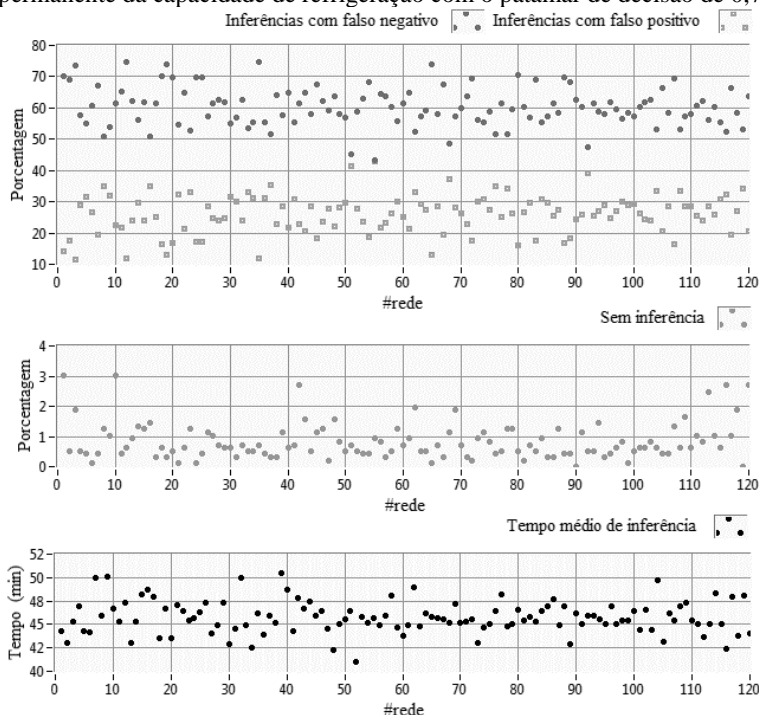
Verifica-se pela figura 30 que o aumento do patamar de decisão, embora corrobore na diminuição do erro de falso positivo, contribui



diretamente para o aumento no tempo médio de inferência e da quantidade de ensaios onde não é possível obter inferência. De forma a balancear os prós e contras, foi arbitrado o patamar 0,7, já utilizado em outros trabalhos (LIMA, 2010b; PENZ, 2011), como o patamar de decisão para as redes de inferência da entrada em regime permanente da capacidade de refrigeração.

A figura 31 apresenta o desempenho individual de cada uma das 120 redes do comitê para o patamar de decisão 0,7. No primeiro gráfico, nota-se uma tendência sistemática do comitê de realizar a inferência após a entrada em regime real. Tal constatação é positiva, visto que diminui a possibilidade de erro de falso positivo. No segundo gráfico, é verificado que para qualquer rede do comitê, é possível obter inferência para pelo menos 96,5% dos ensaios de teste. No terceiro gráfico, verifica-se o tempo médio para obtenção das inferências em cada uma das 120 redes do comitê.


Figura 31 - Comportamento das redes de inferência de entrada em regime permanente da capacidade de refrigeração com o patamar de decisão de 0,7



Fonte: Autor.


Para avaliar a diversidade entre as redes treinadas, a correlação entre às respostas das 120 redes em relação ao conjunto de teste foi utilizada. Na figura 32 é apresentado um histograma contendo a correlação referente as inferências corretas<sup>10</sup>. Já a figura 33 apresenta o histograma de correlações das inferências incorretas<sup>11</sup>.

Figura 32 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração



Fonte: Autor.

Figura 33 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração



Fonte: Autor.

<sup>10</sup> Quando a inferência ocorre em um ponto onde o ensaio já se encontra dentro dos limites de estabilidade.


<sup>11</sup> Quando a inferência ocorre em um ponto onde o ensaio ainda não se encontra dentro dos limites de estabilidade.

As figuras 32 e 33 indicam que não existem duas redes no comitê com comportamento igual, sendo que a maioria possui correlação moderada com as outras. Através desta análise e do comportamento observado na figura 31, é razoável assumir que as redes treinadas possuem diversidade satisfatória.

#### 4.6.2 Comitê para inferência da entrada em regime permanente do consumo

A mesma estratégia apresentada na seção anterior foi utilizada para obtenção do comitê de redes neurais para inferência da entrada em regime permanente do consumo. O comitê de 120 redes foi treinado e apresentado ao conjunto de teste. A diminuição do erro de falso positivo e aumento do tempo de inferência em função do patamar pode ser vista na figura 34.

Figura 34 - Comportamento do comitê de redes de inferência do consumo para diferentes patamares de decisão

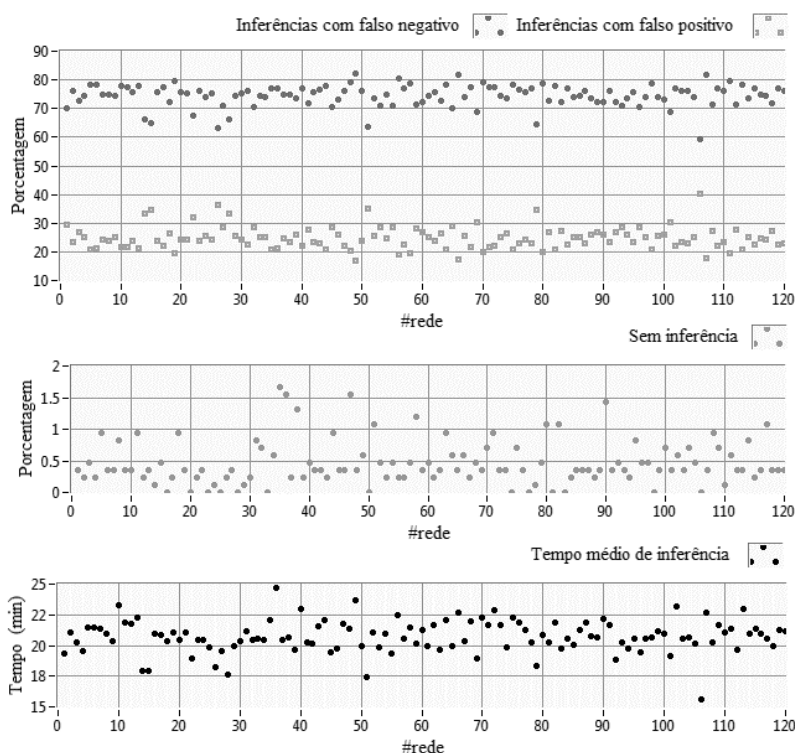


Fonte: Autor.

Como pode ser visto no segundo gráfico, o tempo médio de entrada em regime real dos ensaios de consumo é muito inferior ao de capacidade.

Isto faz com que mesmo para os patamares iniciais, a porcentagem de inferências com erro de falso positivo seja inferior à de erro de falso negativo. Novamente, o patamar 0,7 foi arbitrado por apresentar uma boa relação entre a porcentagem de ensaios com erro de falso positivo e o tempo médio das inferências. A figura 35 apresenta o comportamento de cada rede do comitê em relação ao conjunto de teste.

Figura 35 - Comportamento do comitê de inferência de entrada em regime permanente do consumo com o patamar de decisão de 0,7




Fonte: Autor.

Como pode ser observado no primeiro gráfico, a tendência ao erro de falso negativo é ainda mais acentuada do que no comitê da capacidade. Todas as redes do comitê conseguiram realizar inferência para pelo menos 98% dos ensaios do conjunto de teste.


A correlação entre as redes do comitê também foi testada e é apresentada pelos histogramas das figuras 36 e 37.

Figura 36 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente do consumo



Fonte: Autor.

Figura 37 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente do consumo




Fonte: Autor.

A correlação entre as respostas das redes do comitê, embora mais elevada do que a do comitê de capacidade, reforça o fato de não existir duas redes com correlação perfeita no comitê. Sendo assim, mais uma vez constata-se uma diversidade satisfatória entre as redes do comitê.

### 4.6.3 Comitê para inferência da entrada em regime permanente do COP

Novamente, o comitê de 120 redes foi treinado e apresentado ao conjunto de teste. A diminuição do erro de falso positivo e aumento do tempo de inferência em função do patamar pode ser vista na figura 38.

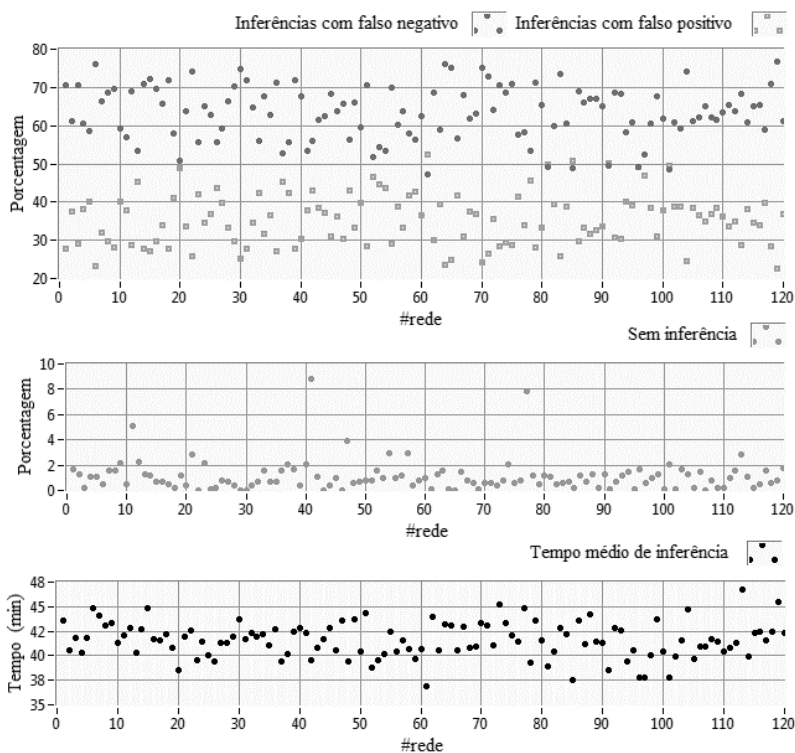
Figura 38 - Comportamento do comitê de redes de inferência do COP para diferentes patamares de decisão



Fonte: Autor.

A variação dos erros em função do patamar de decisão para o COP foi bastante semelhante ao comportamento observado no comitê da capacidade de refrigeração. O patamar 0,7 foi escolhido novamente devida a boa relação entre a porcentagem de ensaios com erro de falso positivo e o tempo médio das inferências. A figura 39 apresenta o comportamento de cada rede do comitê em relação ao conjunto de teste. A tendência ao erro de falso negativo é mais fraca neste comitê do que nos outros dois. Algumas redes chegam a apresentar uma maior porcentagem de ensaios com erros de falso positivo do que de falso negativo.


Figura 39 - Comportamento do comitê de inferência de entrada em regime permanente do COP com o patamar de decisão de 0,7



Fonte: Autor.


A correlação entre as redes do comitê é apresentada pelos histogramas das figuras 40 e 41. Mais uma vez não foram verificadas duas redes com correlação perfeita.

Figura 40 - Histograma de correlações de inferências corretas para o comitê de inferência da entrada em regime permanente do COP



Fonte: Autor.

Figura 41 - Histograma de correlações de inferências incorretas para o comitê de inferência da entrada em regime permanente do COP



Fonte: Autor.

#### 4.7 INTEGRAÇÃO DAS REDES DE INFERÊNCIA DA ENTRADA EM REGIME PERMANENTE

A estratégia utilizada durante este trabalho para integrar as respostas das redes dos comitês de inferência em uma saída única, teve como base as estratégias desenvolvidas por Penz (2011). O processo será inicialmente descrito para a integração do comitê de inferência da




capacidade de refrigeração e em seguida será expandido para os comitês do consumo e do COP.

#### 4.7.1 Regras de integração do comitê de inferência da capacidade de refrigeração

Uma forma muito simples de integrar as respostas de inferência das diversas redes do comitê se baseia na utilização de um limiar mínimo de redes indicando a entrada em regime permanente. Com base nessa ideia, o comitê de inferência da entrada em regime permanente da capacidade de refrigeração foi testado através do conjunto de teste para diversos limiares diferentes. A avaliação dos resultados teve como foco a diferença entre a capacidade de refrigeração no instante da inferência e o valor final de ensaio.

A figura 42 apresenta a diferença média percentual da capacidade no instante da inferência para diversos limiares. Cada ponto do gráfico representa a diferença média percentual dos 842 ensaios do conjunto de teste. É adicionado também ao gráfico o intervalo de confiança de cada ponto para um nível de confiança de 95%.

Figura 42 - Diferença média percentual para diversos limiares no comitê de inferência da capacidade




Fonte: Autor.

Como o objetivo da ferramenta é obter uma inferência da chegada ao regime permanente de forma confiável, é imperativo que o limiar escolhido apresente um intervalo de confiança abaixo dos limites de

estabilidade<sup>12</sup> para a capacidade de refrigeração. Sendo assim, apenas o limiar 120 poderia ser utilizado. No entanto, um valor alto de limiar acarreta em dois problemas já vistos durante a escolha do patamar de decisão das redes. O primeiro é que quanto maior o limiar utilizado, maior será a quantidade de ensaios onde não é possível obter inferência. A segunda é o aumento acentuado do tempo necessário para a obtenção das inferências. A figura 43 ilustra tais problemas.

Figura 43 - Comportamento do comitê de redes de inferência da capacidade de refrigeração para diferentes limiares




Fonte: Autor.

No primeiro gráfico da figura 43, a porcentagem entre ensaios com erro de falso positivo, falso negativo e sem inferência é novamente apresentada para os diferentes limiares. Para o limiar 115 redes, 5% dos ensaios já não conseguem obter inferência, sendo que em 120, esse valor chega a 25%. No segundo gráfico, é possível ver o aumento do tempo médio de inferência em função do limiar. Nos últimos limiares, o tempo cresce de forma bastante acentuada.

<sup>12</sup> Como visto na seção 2.4, os limites de estabilidade para a capacidade de refrigeração são de  $\pm 2\%$  do valor final de ensaio.

De forma a contornar as limitações observadas, é proposto um conjunto de regras baseado em tempos de espera para limiares nos quais o intervalo de confiança da diferença média não está dentro dos limites de estabilidade. No caso da capacidade, limiares inferiores a 120. Tomemos o limiar 30 como exemplo. Na figura 42, o mesmo possui o intervalo de confiança da diferença muito superior ao exigido para caracterizar estabilidade. No entanto, se após a constatação de que 30 redes indicaram inferência, for esperado um certo tempo, tal intervalo pode vir a entrar nos limites de estabilidade. A figura 44 ilustra tal comportamento. O primeiro ponto apresentado é o ponto do limiar 30 na figura 42. Os pontos seguintes indicam o comportamento da diferença média em função do tempo de espera para indicação de estabilidade. Verifica-se pelo gráfico que após 21 minutos, o intervalo de confiança da diferença adentra a região de estabilidade.


Figura 44 - Diferença média percentual versus tempo de espera para o limiar 30



Fonte: Autor.

Gráficos como a da figura 44 foram obtidos para todos os limiares apresentados na figura 43. O resultado é o gráfico da figura 45, onde o tempo de espera para cada limiar é apresentado.

Figura 45 - Tempo de espera para os diversos limiares no comitê de inferência da capacidade



Fonte: Autor.

Através do gráfico da figura 45, foi elaborado um conjunto de regras associadas aos tempos de espera para que o comitê retorne a inferência de entrada em regime permanente. Tal conjunto é apresentado no quadro 9.

Quadro 9 - Conjunto de regras para o comitê de inferência da entrada em regime permanente da capacidade de refrigeração

Regra	Descrição	Tempo de espera (min)
Ñ ind.	Menos de 40 redes	-
Regra 1	Entre 40 e 79 redes	20
Regra 2	Entre 80 e 104 redes	15
Regra 3	Entre 105 e 114 redes	10
Regra 4	Entre 115 e 119 redes	5
Regra 5	120 redes	0

Fonte: Autor.

Para explicar o funcionamento do sistema, utilizemos a Regra 2. A partir do momento que pelo menos 80 redes estiverem inferindo a entrada em regime permanente, um contador é iniciado e, após 15 minutos, o comitê retorna a indicação positiva. Caso antes desse tempo, todas as 120 redes passarem a inferir o regime, a Regra 5 é acionada. Desta forma, ganha a regra que tiver sua condição satisfeita primeiro.

Após a implementação das regras, o comitê foi então exposto novamente ao conjunto de teste. No quadro 10, é possível verificar a quantidade de ensaios que obtiveram inferência através de cada regra.

Quadro 10 - Quantidade de ensaios para cada regra adotada no comitê de inferência da capacidade de refrigeração

<b>Regra</b>	<b>Quant. de ensaios</b>	<b>Quant. em %</b>
Ñ ind.	6	0,7
Regra 1	174	20,7
Regra 2	142	16,9
Regra 3	109	12,9
Regra 4	296	35,2
Regra 5	115	13,7

Fonte: Autor.

Verifica-se pelo quadro 10, que em apenas 6 ensaios não foi possível obter inferência. Sendo assim, o comitê conseguiu inferir a entrada em regime permanente para 99,2% dos ensaios testados. Em relação ao ganho de tempo, o quadro 11 apresenta o tempo médio para obtenção da inferência em cada regra e o valor geral para todos os ensaios. É possível verificar também o tempo médio de entrada em regime real e o tempo médio dos ensaios completos. Por último é apresentado o ganho de tempo da inferência em relação ao tempo médio de ensaio.

Quadro 11 - Tempos médios de inferência para cada regra

<b>Regra</b>	<b>Tempo médio de entrada em regime (min)</b>	<b>Tempo médio de inferência (min)</b>	<b>Tempo médio de ensaio (min)</b>	<b>Ganho de tempo (%)</b>
Regra 1	47,3	73,9	141,5	47,7
Regra 2	42,0	67,0	125,3	46,6
Regra 3	39,8	63,2	125,8	49,8
Regra 4	40,3	61,4	128,0	52,0
Regra 5	39,1	57,5	124,5	53,8
<b>Média</b>	<b>41,8</b>	<b>64,0</b>	<b>129,6</b>	<b>50,1</b>


Fonte: Autor.

#### 4.7.2 Regras de integração do comitê de inferência do consumo

O mesmo procedimento aplicado ao comitê de capacidade foi utilizado para a integração do comitê de inferência da entrada em regime permanente do consumo. O comitê foi inicialmente testado para vários

limiares e a diferença média percentual foi levantado para cada um. A figura 46 apresenta os resultados.


Figura 46 - Diferença média percentual para diversos limiares no comitê de inferência do consumo



Fonte: Autor.

O tempo de espera para cada limiar foi levantado e é apresentado na figura 47.

Figura 47 - Tempo de espera para os diversos limiares no comitê de inferência do consumo



Fonte: Autor.

O gráfico da figura 47 foi utilizado para elaborar o conjunto de regras para inferência da entrada em regime permanente do consumo. Tal conjunto é apresentado no quadro 12.

Quadro 12 - Conjunto de regras para o comitê de inferência da entrada em regime permanente do consumo

<b>Regra</b>	<b>Descrição</b>	<b>Tempo de espera (min)</b>
Ñ ind.	Menos de 80 redes	-
Regra 1	Entre 80 e 94 redes	15
Regra 2	Entre 95 e 114 redes	10
Regra 3	Entre 115 e 119 redes	5
Regra 4	120 redes	0

Fonte: Autor.

O comitê, com seu devido conjunto de regras, foi então apresentado ao conjunto de teste. O quadro 13 apresenta a quantidade de ensaios que obtiveram inferência através de cada regra.

Quadro 13 - Quantidade de ensaios para cada regra adotada no comitê de inferência do consumo

<b>Regra</b>	<b>Quant. de ensaios</b>	<b>Quant. em %</b>
Ñ ind.	3	0,4%
Regra 1	54	6,4%
Regra 2	229	27,3%
Regra 3	333	39,6%
Regra 4	221	26,3%

Fonte: Autor.

O comitê conseguiu inferir a entrada em regime permanente para 99,6% dos ensaios testados. O quadro 14 apresenta o ganho de tempo da inferência em relação ao tempo médio de ensaio.

Quadro 14 - Tempos médios de inferência para cada regra


<b>Regra</b>	<b>Tempo médio de entrada em regime (min)</b>	<b>Tempo médio de inferência (min)</b>	<b>Tempo médio de ensaio (min)</b>	<b>Ganho de tempo (%)</b>
Regra 1	22,3	45,0	124,6	63,9
Regra 2	18,1	41,9	134,9	68,9
Regra 3	13,5	33,6	126,3	73,4
Regra 4	15,6	31,8	129,8	75,5
<b>Média</b>	<b>15,9</b>	<b>36,2</b>	<b>129,5</b>	<b>72,1</b>

Fonte: Autor.

4.7.3 Regras de integração do comitê de inferência do COP

Assim como nos outros, o comitê de inferência do COP foi testado para vários limiares e a diferença média percentual foi levantada para cada um. A figura 48 apresenta os resultados.


Figura 48 - Diferença média percentual para diversos limiares no comitê de inferência do COP



Fonte: Autor.

O tempo de espera para cada limiar foi levantado e é apresentado na figura 49.

Figura 49 - Tempo de espera para os diversos limiares no comitê de inferência do COP



Fonte: Autor.

O conjunto de regras para inferência da entrada em regime permanente do consumo foi elaborado a partir do gráfico da figura 49 e é apresentado no quadro 15.



Quadro 15 - Conjunto de regras para o comitê de inferência da entrada em regime permanente do COP

<b>Regra</b>	<b>Descrição</b>	<b>Tempo de espera (min)</b>
Ñ ind.	Menos de 60 redes	-
Regra 1	Entre 60 e 84 redes	20
Regra 2	Entre 85 e 109 redes	15
Regra 3	Entre 110 e 114 redes	10
Regra 4	Entre 115 e 119 redes	5
Regra 5	120	0

Fonte: Autor.

O comitê, com seu devido conjunto de regras, foi então apresentado ao conjunto de teste. O quadro 16 apresenta a quantidade de ensaios que obtiveram inferência através de cada regra.

Quadro 16 - Quantidade de ensaios para cada regra adotada no comitê de inferência do COP

<b>Regra</b>	<b>Quant. de ensaios</b>	<b>Quant. em %</b>
Ñ ind.	16	1,9
Regra 1	116	13,8
Regra 2	217	25,8
Regra 3	66	7,8
Regra 4	310	36,8
Regra 5	117	13,9

Fonte: Autor.

O comitê conseguiu inferir a entrada em regime permanente para 98,1% dos ensaios testados. O quadro 14 apresenta o ganho de tempo da inferência em relação ao tempo médio de ensaio.

Quadro 17 - Tempos médios de inferência para cada regra

<b>Regra</b>	<b>Tempo médio de entrada em regime (min)</b>	<b>Tempo médio de inferência (min)</b>	<b>Tempo médio de ensaio (min)</b>	<b>Ganho de tempo (%)</b>
Regra 1	45,0	70,6	131,4	46,2
Regra 2	42,0	67,0	133,8	49,9
Regra 3	36,3	58,7	124,4	52,8

Regra 4	37,6	57,9	128,8	55,0
Regra 5	35,5	55,5	132,3	58,1
<b>Média</b>	<b>39,4</b>	<b>61,8</b>	<b>130,6</b>	<b>52,7</b>

Fonte: Autor.

#### 4.8 COMITÊS DE REDES NEURAIIS PARA PROGNÓSTICO DO VALOR FINAL DE ENSAIO

As redes do comitê de prognóstico do valor final dos parâmetros de desempenho utilizaram o mesmo conjunto de treinamento e teste das redes de inferência. De forma a melhor verificar a distribuição das respostas das redes de prognóstico, comitês com uma grande quantidade de redes foram treinados para cada parâmetro de desempenho, sendo 500 redes em cada comitê. A integração das respostas das redes de prognóstico foi feita através da média das respostas de um subconjunto de redes do comitê. Dos 500 prognósticos obtidos, apenas 400 são utilizados na média do valor final. Os 50 prognósticos de valor mais baixo, assim como os 50 de valor mais alto, são descartados. Tal estratégia tem como objetivo atenuar a influência de redes com comportamento muito destoante da média.


Abaixo serão apresentados os resultados obtidos pela aplicação do sistema completo (comitê de inferência e prognóstico).

##### 4.8.1 Comitê para prognóstico do valor final da capacidade de refrigeração.

O comitê de prognóstico foi utilizado em conjunto com o comitê de inferência para o conjunto de teste. O histograma da figura 50 apresenta a diferença percentual entre a valor obtido pelo prognóstico e o valor final de ensaio para os ensaios do conjunto de teste. Como apresentado na seção 4.7.1, o comitê de inferência da capacidade não conseguiu realizar inferência para seis ensaios, sendo assim, o prognóstico foi realizado para 836 ensaios. Levando em conta o sinal da diferença, verifica-se uma diferença média de +0,06%. Essa pequena tendência à diferença positiva pode ser observada no histograma da figura 50. Caso o sinal não seja considerado, a diferença média fica em 0,61%. Apenas 16 ensaios apresentaram diferença percentual acima da faixa de  $\pm 2\%$ . Desses 16 ensaios, 11 apresentaram estabilização momentânea. Nos outros 5, a estabilização ocorreu de forma bastante lenta, levando a ferramenta de inferência a inferir a entrada em regime antes do tempo.

Em relação a eficiência do comitê de prognóstico em aproximar o valor da capacidade obtido logo após a inferência ao valor final de ensaio, verificou-se que em 66% dos ensaios, o comitê contribuiu para a diminuição da diferença em relação ao valor final. Nos 32% restantes, foi verificado um aumento da diferença após o prognóstico em relação ao valor obtido pela inferência.

Figura 50 - Histograma das diferenças entre prognóstico e valor final da capacidade de refrigeração



Fonte: Autor.

O quadro 18 apresenta a porcentagem de ensaios que obtiveram diferença entre o prognóstico e o valor final de ensaio dentro de determinadas faixas.

Quadro 18 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para a capacidade de refrigeração


Faixas de diferença	Percentual de ensaios válidos
±1%	81,4%
±1,5%	93,5%
±2%	98,1%
±3%	99,4%

Fonte: Autor.

4.8.2 Comitê para prognóstico do valor final do consumo

O histograma da figura 51 apresenta a diferença percentual entre a valor obtido pelo prognóstico e o valor final de ensaio para os ensaios do conjunto de teste do consumo. Assim como no comitê de prognóstico da capacidade de refrigeração, verificou-se uma tendência à diferença positiva, com uma diferença média de +0,15%. Em módulo, a diferença média verificada foi de 0,64%, sendo que 43 ensaios apresentaram diferença percentual acima da faixa de  $\pm 2\%$ . Desses 43 ensaios, 24 apresentaram estabilização momentânea. Outros 11 apresentaram estabilização bastante lenta, levando a ferramenta de inferência a um erro de falso positivo. Nos outros 8 ensaios, a ferramenta de prognóstico teve uma má atuação. Tal fato será abordado na discussão dos resultados. Foi verificado que em 64% dos ensaios, o comitê contribuiu para a diminuição da diferença em relação ao valor final.

Figura 51 - Histograma das diferenças entre prognóstico e valor final do consumo



Fonte: Autor.

O quadro 19 apresenta a porcentagem de ensaios que obtiveram diferença entre o prognóstico e o valor final de ensaio dentro de determinadas faixas.

Quadro 19 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para o consumo


Faixas de diferença	Percentual de ensaios válidos
$\pm 1\%$	77,9%
$\pm 1,5\%$	90,7%
$\pm 2\%$	94,9%
$\pm 3\%$	98,6%

Fonte: Autor.

4.8.3 Comitê para prognóstico do valor final do COP

O histograma da figura 52 apresenta a diferença percentual entre a valor obtido pelo prognóstico e o valor final de ensaio para os ensaios do conjunto de teste do COP. Novamente, uma tendência à diferença positiva foi observada, com uma diferença média de +0,12%. Em módulo, a diferença média verificada foi de 0,60%, sendo que 21 ensaios apresentaram diferença percentual acima da faixa de  $\pm 2\%$ . Desses 21 ensaios, 12 apresentaram estabilização momentânea. Nos outros 9, houve erro de falso positivo pela ferramenta de inferência devido a estabilização lenta. Foi verificado que em 69% dos ensaios, o comitê contribuiu para a diminuição da diferença em relação ao valor final.

Figura 52 - Histograma das diferenças entre prognóstico e valor final do COP



Fonte: Autor.

O quadro 20 apresenta a porcentagem de ensaios que obtiveram diferença entre o prognóstico e o valor final de ensaio dentro de determinadas faixas.

Quadro 20 - Porcentagem de ensaios válidos para várias faixas de diferença percentual entre prognóstico e valor final de ensaio para o COP

<b>Faixas de diferença</b>	<b>Percentual de ensaios válidos</b>
$\pm 1\%$	83,1%
$\pm 1,5\%$	93,8%
$\pm 2\%$	97,5%
$\pm 3\%$	99,3%

Fonte: Autor.

5 ANÁLISE DOS RESULTADOS

Neste capítulo, os resultados obtidos pelos módulos neurais, formados pelos comitês de inferência e prognóstico de cada parâmetro de desempenho, serão apresentados de forma completa e comparados com os objetivos iniciais do trabalho. Também serão feitas análises quanto ao comportamento dos módulos em relação as faixas de capacidade e ao fluido refrigerante utilizado. Os desafios que surgiram durante a implementação das ferramentas e as principais limitações das mesmas também serão abordados.

5.1 MÓDULO NEURAL DA CAPACIDADE DE REFRIGERAÇÃO

O módulo neural da capacidade de refrigeração, composto pelo comitê de inferência de entrada em regime permanente e o comitê de prognostico do valor final da capacidade de refrigeração, apresentou desempenho dentro do esperado nos objetivos do trabalho. O quadro 21 apresenta um resumo dos resultados obtidos pelo módulo neural ao ser apresentado ao conjunto de teste.

Quadro 21 - Resumo do desempenho do módulo neural da capacidade de refrigeração

Ensaio de teste	842
Percentual de ensaios com inferência	99,3%
Percentual de prognósticos dentro da faixa de $\pm 2\%$	98,1%
Diferença média percentual de prognóstico <sup>13</sup>	(+0,06 $\pm$ 1,70)%
Tempo médio de entrada em regime permanente	41,8 minutos
Tempo médio de inferência	64,7 minutos
Tempo médio dos ensaios	129,6 minutos
Ganho percentual de tempo	50,1%


Fonte: Autor.

O módulo foi capaz de obter inferência para a quase totalidade dos ensaios de teste, sendo que a grande maioria dos prognósticos apresentou diferença dentro da faixa de  $\pm 2\%$  em relação ao valor final de ensaio. O tempo médio de inferência apresentou um ganho de 50% em relação ao

<sup>13</sup> O nível de confiança utilizado para o cálculo de todos os intervalos de confiança deste capítulo foi de 95%.

tempo médio de ensaio. No entanto, as inferências demoraram em média 23 minutos a mais do que a entrada em regime real. Tal fato evidencia que ainda existe espaço para redução do tempo de inferência da ferramenta. A busca por tal redução esbarra, porém no maior problema observado durante a elaboração da ferramenta de inferência, ensaios com estabilização momentânea. Ao analisar os ensaios do conjunto de teste, verificou-se que as maiores diferenças entre o prognóstico e o valor final de ensaio foram ocasionados devido a estabilizações momentâneas. O ensaio da figura 53, por exemplo, apresentou uma diferença entre prognóstico e valor final de ensaio de +7,2%, a maior diferença do conjunto de teste.

Figura 53 - Ensaio com a maior diferença entre prognóstico e valor final de ensaio para a capacidade de refrigeração



Fonte: Autor.

### 5.1.1 Análise por faixas de capacidade

Como visto na seção 4.5, o conjunto de teste é formado por ensaios de compressores de diversas capacidades. De forma a testar a eficiência do módulo neural da capacidade para diferentes faixas de capacidade, o conjunto de teste foi dividido em três subconjuntos relativos a ensaios de capacidade alta, média e baixa. Cinco ensaios críticos que apresentaram estabilização momentânea foram retirados dessa análise para não influenciar as diferenças médias de cada subconjunto. A resposta do módulo para cada um dos subconjuntos é apresentada no quadro 22.



Quadro 22 - Desempenho do módulo neural da capacidade de refrigeração para diferentes faixas de capacidade

	Faixa de capacidade		
	Baixa	Média	Alta
Faixa de capacidade	Até 100 W	(100 a 175) W	(175 a 265) W
Ensaio de teste	32	87	718
Ensaio sem inferência	0	2	4
Prognósticos fora da faixa de $\pm 2\%$	0	1	10
Diferença média de prognóstico (W)	$(-0,37 \pm 0,87)$	$(-0,19 \pm 2,57)$	$(+0,23 \pm 2,84)$
Diferença média de prognóstico (%)	$(-0,85 \pm 1,43)$	$(-0,15 \pm 1,78)$	$(+0,11 \pm 1,39)$

Fonte: Autor.

O quadro 22 apresenta o desempenho dos subconjuntos de duas formas. Na primeira, as diferenças médias, junto com seus intervalos de confiança, são apresentadas em watts. Nesta representação, verifica-se um intervalo de confiança menor para o subconjunto de baixa capacidade. Também é possível observar que, ao contrário do subconjunto de alta capacidade, os subconjuntos média e baixa capacidade apresentaram uma maior tendência à diferença negativa.

Na segunda forma, a diferença média é apresentada como porcentagem do valor final de ensaio. Nesta representação, verifica-se que o desempenho do subconjunto de alta capacidade foi superior ao dos outros dois. Tal resultado, embora relevante, deve ser interpretado com cautela, visto que a diferença da quantidade de ensaios entre os subconjuntos é bastante alta.

### 5.1.2 Análise por fluido refrigerante

De forma similar à análise por faixas de capacidade, o conjunto de teste foi dividido em dois subconjuntos referentes aos dois fluidos refrigerantes utilizados pelos compressores ensaiados, R-134a e R-600a. O quadro 23 apresenta o desempenho do módulo para cada subconjunto. Novamente, a diferença média foi retratada de forma percentual e em watts. O subconjunto do fluido R-134a apresentou um desempenho superior tanto na análise percentual, quanto na análise em watts. Este

resultado, no entanto, se deve ao fato de que a totalidade dos ensaios de baixa capacidade e uma boa parte dos ensaios de média capacidade estarem dentro do subconjunto do fluido R-600a, o que explica a tendência às diferenças negativas. Como o subconjunto do fluido R-134a é composto, em sua maioria, por ensaios de alta capacidade, há uma menor variância da diferença média no mesmo.

Quadro 23 - Desempenho do módulo neural da capacidade de refrigeração para diferentes fluidos refrigerantes

	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	667	170
Ensaio sem inferência	4	2
Diferença média de prognóstico (W)	(+0,27±2,73)	(-0,28±2,83)
Diferença média de prognóstico (%)	(+0,13±1,34)	(-0,29±1,80)

Fonte: Autor.

## 5.2 MÓDULO NEURAL DO CONSUMO

O quadro 24 apresenta um resumo dos resultados obtidos pelo módulo neural do consumo ao ser apresentado ao conjunto de teste.

Quadro 24 - Resumo do desempenho do módulo neural do consumo

Ensaio de teste	840
Percentual de ensaios com inferência	99,6%
Percentual de prognósticos dentro da faixa de $\pm 2\%$	94,9%
Diferença média percentual de prognóstico	(+0,15±1,98)%
Tempo médio de entrada em regime permanente	15,9 minutos
Tempo médio de inferência	36,2 minutos
Tempo médio dos ensaios	129,5 minutos
Ganho percentual de tempo	72,1%


Fonte: Autor.

O tempo médio de inferência apresentou um ganho de mais de 70% em relação ao tempo médio de ensaio. Quando comparado ao tempo

médio de entrada em regime permanente, percebe-se uma diferença de apenas 10 minutos.

Ao analisar os ensaios do conjunto de teste, novamente foi verificado que as maiores diferenças entre o prognóstico e o valor final de ensaio foram ocasionados devido a estabilizações momentâneas. O ensaio da figura 54, por exemplo, apresentou uma diferença entre prognóstico e valor final de +7,7%, a maior diferença do conjunto de teste.

Figura 54 - Ensaio com a maior diferença entre prognóstico e valor final para o consumo



Fonte: Autor.

### 5.2.1 Análise por faixas de capacidade

Assim como no módulo para capacidade de refrigeração, o conjunto de teste para o consumo foi dividido em três subconjuntos relativos a ensaios de capacidade alta, média e baixa. Quatro ensaios críticos que apresentaram estabilização momentânea foram retirados dessa análise para não influenciar as diferenças médias de cada subconjunto. A resposta do módulo para cada um dos subconjuntos é apresentada no quadro 25. O comportamento observado no módulo de capacidade se repete no módulo de consumo. Na análise em watts, os ensaios de baixa capacidade apresentaram a menor diferença. No entanto, na análise percentual da diferença, os ensaios de alta capacidade apresentam o melhor resultado. Novamente é válida a ressalva da diferença significativa da quantidade de ensaios presentes em cada subconjunto para a interpretação dos resultados.

Quadro 25 - Desempenho do módulo neural do consumo para diferentes faixas de capacidade

	Faixa de capacidade		
	Baixa	Média	Alta
Faixa de capacidade	Até 100 W	(100 a 175) W	(175 a 265) W
Ensaaios de teste	42	98	696
Ensaaios sem inferência	0	0	3
Prognósticos fora da faixa de $\pm 2\%$	5	11	23
Diferença média de prognóstico (W)	$(-0,16 \pm 0,79)$	$(+0,01 \pm 2,01)$	$(+0,20 \pm 1,79)$
Diferença média de prognóstico (%)	$(-0,36 \pm 2,33)$	$(-0,04 \pm 2,31)$	$(+0,20 \pm 1,64)$

Fonte: Autor.

### 5.2.2 Análise por fluido refrigerante

Novamente, o conjunto de teste foi dividido em dois subconjuntos referentes aos dois fluidos refrigerantes utilizados pelos compressores ensaiados, R-134a e R-600a. O quadro 23 apresenta o desempenho do módulo para cada subconjunto.

A diferença média foi retratada de forma percentual e em watts. Enquanto na análise percentual o subconjunto do fluido R-134a apresentou um desempenho um pouco superior, na análise em watts, o fluido R-600a se saiu melhor. Mais uma vez, tal resultado se deve ao fato de que a totalidade dos ensaios de baixa capacidade, e uma boa parte dos ensaios de média capacidade, estar dentro do subconjunto do fluido R-600a. Motivo esse, que também justifica a tendência do subconjunto do fluido R-600a a apresentar diferenças negativas.

Quadro 26 - Desempenho do módulo neural do consumo para diferentes fluidos refrigerantes

	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	653	183
Ensaio sem inferência	3	0
Diferença média de prognóstico (W)	(+0,27±1,78)	(-0,04±1,76)
Diferença média de prognóstico (%)	(+0,22±1,68)	(-0,10±2,07)

Fonte: Autor.

### 5.3 MÓDULO NEURAL DO COP

O quadro 27 apresenta um resumo dos resultados obtidos pelo módulo neural do COP ao ser apresentado ao conjunto de teste.

Quadro 27 - Resumo do desempenho do módulo neural do COP

Ensaio de teste	842
Percentual de ensaios com inferência	98,1%
Percentual de prognósticos dentro da faixa de $\pm 2\%$	97,5%
Diferença média percentual de prognóstico	(+0,12±1,62)%
Tempo médio de entrada em regime permanente	39,4 minutos
Tempo médio de inferência	61,8 minutos
Tempo médio dos ensaios	130,6 minutos
Ganho percentual de tempo	52,7%


Fonte: Autor

O tempo médio de inferência apresentou um ganho de mais de 50% em relação ao tempo médio de ensaio. No entanto, assim como no módulo neural de capacidade, as inferências foram realizadas, em média, 20 minutos após a entrada em regime real.

Ao analisar os ensaios do conjunto de teste, novamente foi verificado que as maiores diferenças entre o prognóstico e o valor final de ensaio do módulo de consumo foram ocasionadas devido às estabilizações momentâneas. O ensaio da figura 52, por exemplo,

apresentou uma diferença entre prognóstico e valor final de ensaio de +5,0%, a segunda maior diferença do conjunto de teste.

Figura 55 - Ensaio com a segunda maior diferença entre prognóstico e valor final para o COP



Fonte: Autor.

### 5.3.1 Análise por faixas de capacidade

O conjunto de teste para o COP foi dividido em três subconjuntos relativos a ensaios de capacidade alta, média e baixa. Três ensaios críticos que apresentaram estabilização momentânea foram retirados dessa análise para não influenciar as diferenças médias de cada subconjunto. A resposta do módulo para cada um dos subconjuntos é apresentada no quadro 28. Para análise do desempenho, a diferença média é apresentada como porcentagem do valor final de ensaio e também na forma adimensional. Diferentemente dos outros módulos, tanto a análise em porcentagem quanto a adimensional indicaram um melhor desempenho no subconjunto de ensaios de alta capacidade. Novamente, é válida a ressalva da diferença significativa da quantidade de ensaios presentes em cada subconjunto quanto a interpretação dos resultados.

Quadro 28 - Desempenho do módulo neural do COP para diferentes faixas de capacidade

	Faixa de capacidade		
	Baixa	Média	Alta
Faixa de capacidade	Até 100 W	(100 a 175) W	(175 a 265) W
Ensaio de teste	37	93	709
Ensaio sem inferência	8	4	4
Prognósticos fora da faixa de $\pm 2\%$	5	4	9
Diferença média de prognóstico (W)	$(-0,014 \pm 0,048)$	$(-0,005 \pm 0,034)$	$(+0,004 \pm 0,026)$
Diferença média de prognóstico (%)	$(-0,81 \pm 2,81)$	$(-0,29 \pm 2,08)$	$(+0,20 \pm 1,33)$

Fonte: Autor.

### 5.3.2 Análise por fluido refrigerante

O conjunto de teste foi dividido em dois subconjuntos referentes aos dois fluidos refrigerantes utilizados pelos compressores ensaiados, R-134a e R-600a. O quadro 29 apresenta o desempenho do módulo para cada subconjunto.

Quadro 29 - Desempenho do módulo neural do COP para diferentes fluidos refrigerantes

	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	664	175
Ensaio sem inferência	3	13
Diferença média de prognóstico (W)	$(+0,004 \pm 0,025)$	$(-0,006 \pm 0,037)$
Diferença média de prognóstico (%)	$(+0,21 \pm 1,29)$	$(-0,31 \pm 2,18)$

Fonte: Autor.

A diferença média foi retratada de forma percentual na forma adimensional. O subconjunto do fluido R-134a apresentou melhor desempenho nas duas análises. Tal fato corrobora com os resultados da análise por faixa de capacidade, visto que o subconjunto do fluido R-134a é composto, em sua maioria, por ensaios de alta capacidade.

5.4 DISCUSSÃO DOS RESULTADOS

Como estabelecido nos objetivos específicos deste trabalho, os limites de diferença média entre os prognósticos obtidos pelos módulos neurais e os valores finais dos ensaios de teste deveriam estar dentro das seguintes faixas:

- Capacidade:  $\pm 2\%$  do valor final de ensaio;
- Consumo:  $\pm 2\%$  do valor final de ensaio;
- COP:  $\pm 3\%$  do valor final de ensaio.

Ao verificar os resultados das ferramentas, resumidos no quadro 30, verifica-se que os três módulos apresentaram diferenças dentro dos limites propostos, para um nível de confiança de 95%.

Quadro 30 - Resumo dos resultados dos módulos neurais

	Parâmetro de desempenho		
	CAP	CONS	COP
Ensaio de teste	842	840	842
Ensaio sem inferência	6	3	16
Ensaio desconsiderado por estabilização momentânea	5	4	3
Diferença média de prognóstico (%)	(+0,05 $\pm$ 1,48)	(+0,15 $\pm$ 1,78)	(+0,11 $\pm$ 1,56)
Ganho percentual de tempo	50,1%	72,1%	52,7%

Fonte: Autor.

Os resultados obtidos pelo módulo neural da capacidade mostram que é possível utilizar as medições obtidas através do método A – calorímetro de fluido secundário – no desenvolvimento das ferramentas de inferência e prognóstico do valor final da capacidade de refrigeração.



Mesmo com uma dinâmica mais lenta do que o método F – medidor de vazão mássica no estado líquido – foi possível obter um ganho de tempo de mais de 50% em relação ao tempo de ensaio completo.

O quadro 31 apresenta um resumo dos resultados dos módulos em relação aos subconjuntos relativos as faixas de capacidade. Foi verificado comportamento semelhante entre os módulos de capacidade e consumo. Na análise absoluta da diferença, em watts, os ensaios de alta capacidade apresentaram diferenças superiores aos ensaios de baixa capacidade. No entanto, na análise percentual, o subconjunto de alta capacidade apresentou melhores resultados. Se confrontados com os limites de diferença percentual estipulados, verifica-se que os subconjuntos de baixa capacidade, e o subconjunto de média capacidade para o consumo, apresentaram resultados fora das faixas estipuladas, para um nível de confiança de 95%. Este desempenho superior das ferramentas para com os ensaios de alta capacidade pode ser atribuído a maior presença de ensaios de alta capacidade nos conjuntos de treinamento e teste das redes neurais. Outra hipótese para explicar tal diferença está associada a maior instabilidade dos ensaios de baixa capacidade, visto que muitas das variáveis medidas estão nos limites inferiores das faixas de medição.

Quadro 31 - Resumo dos resultados dos módulos neurais em função da faixa de capacidade

Capacidade	Faixa de capacidade		
	Baixa	Média	Alta
Ensaio de teste	32	87	718
Diferença média (W)	-0,37±0,87	-0,19±2,57	+0,23±2,84
Diferença média (%)	-0,85±1,43	-0,15±1,78	+0,11±1,39
Consumo	Faixa de capacidade		
	Baixa	Média	Alta
Ensaio de teste	42	98	696
Diferença média (W)	-0,16±0,79	+0,01±2,01	+0,20±1,79
Diferença média (%)	-0,36±2,33	-0,04±2,31	+0,20±1,64
COP	Faixa de capacidade		
	Baixa	Média	Alta
Ensaio de teste	37	93	709
Diferença média (adimensional)	-0,014±0,048	-0,005±0,034	+0,004±0,026
Diferença média (%)	-0,81±2,81	-0,29±2,08	+0,20±1,33

Fonte: Autor.

O módulo neural do COP apresentou um comportamento diferente na análise por faixas e capacidade. O mesmo não é afetado da mesma forma que os outros dois, visto que um ensaio de alta capacidade não necessariamente tem um COP maior do que um de baixa capacidade. Como este módulo possui um limite de diferença percentual superior aos outros dois, apenas o subconjunto de baixa capacidade apresentou resultados fora da faixa estipulada. Uma última ressalva à diferença no número de ensaios entre os subconjuntos. Uma análise mais confiável seria obtida com um número maior de ensaios nos subconjuntos de baixa e média capacidade.

Em relação à análise por fluido refrigerante, não foi verificada uma correlação significativa entre desempenho dos módulos neurais e tipo de fluido refrigerante do ensaio. As diferenças de desempenho observadas durante a análise dos subconjuntos parecem estar mais relacionadas com a distribuição das faixas de capacidade do que com o fluido refrigerante em si. Como quase todos os ensaios de baixa e média capacidade utilizam o fluido R-600a, é esperado que o subconjunto deste fluido apresente uma diferença média percentual superior ao subconjunto do fluido R-134a, onde quase a totalidade dos ensaios é alta capacidade. O resumo da análise por fluido refrigerante é apresentado no quadro 32.

Quadro 32 - Resumo dos resultados dos módulos neurais em função do fluido refrigerante

Capacidade	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	667	170
Diferença média (W)	(+0,27±2,73)	(-0,28±2,83)
Diferença média (%)	(+0,13±1,34)	(-0,29±1,80)
Consumo	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	653	183
Diferença média (W)	(+0,27±1,78)	(-0,04±1,76)
Diferença média (%)	(+0,22±1,68)	(-0,10±2,07)
COP	Fluido refrigerante	
	R-134a	R-600a
Ensaio de teste	664	175
Diferença média (adimensional)	(+0,004±0,025)	(-0,006±0,037)
Diferença média (%)	(+0,21±1,29)	(-0,31±2,18)

Fonte: Autor.

## 5.5 ANÁLISE DE DESEMPENHO DAS FERRAMENTAS DE INFERÊNCIA E PROGNÓSTICO

O quadro 33 apresenta um resumo dos resultados dos comitês de inferência e prognóstico para os três parâmetros de desempenho. Os comitês de inferência da entrada em regime permanente foram capazes de obter inferência para pelo menos 98% dos ensaios de teste, sendo que ao menos 93% dessas inferências foram corretas, feitas em momentos onde o ensaio já se encontrava em regime permanente. Os resultados dos comitês de prognóstico, no entanto, indicam que em quase 35% dos ensaios de teste, os comitês de prognóstico retornam um valor mais distante do resultado final do que aquele verificado no momento da inferência.

Quadro 33 - Comparação de desempenho entre ferramentas de inferência e prognóstico


<b>Comitês de inferência</b>	<b>CAP</b>	<b>CONS</b>	<b>COP</b>
Percentual de ensaios com inferência	99,29%	99,64%	98,10%
Percentual de inferências sem erro de falso positivo	95,69%	93,67%	94,79%
<b>Comitês de prognóstico</b>	<b>CAP</b>	<b>CONS</b>	<b>COP</b>
Percentual de ensaios onde prognóstico melhora o resultado	65,56%	63,69%	68,76%

Fonte: Autor.

Durante a análise dos resultados, verificou-se que as ferramentas de inferência têm seu desempenho comprometido frente a ensaios com estabilização momentânea, já discutidos ao longo do trabalho, e também em ensaios com estabilização muito lenta. Neste último caso, as características utilizadas pelas redes neurais para detectar a chegada ao regime permanente, tais como pequenas diferenças entre as médias utilizadas, são observadas antes da chegada real ao regime, aumentando assim a chance de erro de falso positivo. A figura 56 apresenta um exemplo deste tipo de ensaio. Uma forma de aumentar a confiabilidade da ferramenta de inferência, já testada em trabalhos anteriores (PENZ, 2011), seria a utilização de técnicas de inteligência artificial auxiliares

para a confirmação da chegada do regime permanente. Penz (2011) utilizou ferramentas baseadas em redes *fuzzy*-bayesianas em conjunto com as ferramentas de inferência por redes neurais de forma a obter mais robustez na inferência do regime permanente.


Figura 56 - Ensaio de capacidade com estabilização lenta e erro de falso positivo



Fonte: Autor.

Existem alguns motivos que levam as ferramentas de prognóstico a retornar um valor mais distante do valor final de ensaio do que aquele verificado no momento da inferência. Dentre eles, destacar-se o fato de que a ferramenta é muito dependente de como o ensaio se comporta após entrar nos limites de estabilidade. Utilizemos o ensaio de consumo da figura 57 como exemplo. A ferramenta de inferência detecta a entrada do regime em 50 minutos. Como o ensaio já havia adentrado os limites de estabilidade, tal inferência é considerada correta. No entanto após a inferência, verifica-se que o consumo volta a subir e logo em seguida estabiliza no valor final. No momento da inferência, o valor do consumo era de 101,9 W. Como a ferramenta de prognóstico utiliza apenas as 45 amostras obtidas logo antes do ponto de inferência, o prognóstico resultante foi de 101,0 W, sendo que o valor final do ensaio foi 103,2 W. Não havia como a ferramenta prever, apenas com os dados de antes da inferência, que o consumo voltaria a subir.


Figura 57 - Ensaio de consumo com estabilização momentânea



Fonte: Autor

Uma forma de tentar contornar tal problema seria a utilização de uma entrada adicional nas redes de prognóstico que apresentasse o comportamento do ensaio logo após o momento da inferência. Como descrito na seção 4.2.5, umas das estratégias utilizadas para evitar erros de falso positivo por parte da ferramenta de inferência consiste em um tempo de espera de 400 segundos (40 amostras) após a detecção do regime para que a inferência seja validada. Estas amostras podem ser utilizadas pela rede de prognóstico para que a mesma tenha mais informações a respeito do comportamento do ensaio nas proximidades do momento da inferência. Uma adaptação da figura 19, onde são apresentadas as entradas da rede de prognóstico é mostrada na figura 58. Nessa figura, M0 representa uma possível nona entrada utilizando as 40 amostras disponíveis após o ponto de inferência.

Figura 58 - Representação gráfica da adição de uma possível nona entrada à rede de prognóstico



Fonte: Autor.

## 6 CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo geral o aprimoramento e avaliação de ferramentas de inteligência artificial utilizadas para a inferência de entrada em regime permanente e prognóstico do valor final de parâmetros de desempenho de compressores herméticos. Nas conclusões a seguir, serão abordados os objetivos específicos e algumas considerações sobre a análise dos resultados.

### 6.1 CONCLUSÕES

Após a adaptação das ferramentas desenvolvidas por Lima (2010b) e Penz (2011), três módulos neurais, referentes aos três parâmetros de desempenho de compressores abordados neste trabalho, foram treinados e testados através de uma quantidade de ensaios de desempenho não antes utilizada para tal fim.

No tocante a substituição do método F de obtenção da capacidade de refrigeração pelo método A, verificou-se que as arquiteturas de rede selecionadas em trabalhos anteriores se mostraram adequadas para esta nova dinâmica, retornando um desempenho tão bom quanto no método anterior.

Em relação à biblioteca de ensaios analisada, foi feita uma seleção criteriosa baseada em pré-requisitos do sistema neural. Um total de 1117 ensaios foram aprovados para as etapas de treinamento, validação e teste das redes neurais. O conjunto incluía ensaios de compressores de alta, média e baixa capacidade, assim como compressores que utilizavam os fluidos refrigerantes R-600a e R-134a. Foram observadas diferentes dinâmicas nos ensaios de capacidade de refrigeração e coeficiente de performance. Os conjuntos de treinamento e validação das redes neurais foram montados com o objetivo de obter redes capazes de realizar generalização para todas as faixas de capacidade presentes no conjunto de ensaio, levando em conta também as diferentes dinâmicas encontradas durante a análise da biblioteca de ensaios. A decisão de não utilizar reposição de ensaios quando da seleção do conjunto de treinamento das redes teve como objetivo gerar uma maior variedade de ensaios em cada conjunto. Tal método, embora tenha apresentado bons resultados, não é comum na literatura, sendo o método *bootstrap* o mais usual.

A utilização de comitês de redes neurais para a formação dos módulos neurais foi aplicada para os três parâmetros de desempenho. A estratégia utilizada para a integração das respostas das redes dos comitês de inferência foi exposta passo a passo e apresentou resultados bastante

robustos, permitindo uma boa relação entre a qualidade das inferências obtidas e o tempo necessário para a obtenção das mesmas.

Ao apresentar os comitês treinados aos seus respectivos conjuntos de teste, verificou-se que, apesar das estratégias aplicadas para evitar erros de falso positivo, ensaios que apresentaram estabilizações momentâneas foram os que tiveram as maiores diferenças entre prognóstico e valor final de ensaio.

Os resultados gerais dos três módulos neurais, resumidos no quadro 30, indicam que os mesmos apresentaram desempenho dentro das faixas de diferença estipuladas. Enquanto os módulos neurais da capacidade e do COP obtiveram uma redução de mais de 50% em relação ao tempo de ensaio completo, o módulo do consumo obteve uma redução de mais de 70%.

Já na análise por faixas de capacidade, foi verificado que os subconjuntos de ensaios de baixa capacidade apresentaram resultados de desempenho fora das faixas de diferença estipuladas para os três módulos neurais. No módulo do consumo, o subconjunto de ensaios média capacidade também apresentou desempenho fora da faixa estipulada. A diferença de desempenho entre faixas de capacidade pode ser explicada, em parte, pela maior presença de ensaios de alta capacidade nos conjuntos de treinamento e teste das redes, assim como pela maior instabilidade dos ensaios de baixa capacidade. Embora os resultados obtidos através dessa análise tenham sido interessantes para o entendimento do funcionamento do sistema neural proposto, é importante ressaltar a diferença na quantidade de ensaios disponíveis para cada faixa. Uma maior quantidade de ensaios de baixa e média capacidade teria sido interessante tanto para a fase de treinamento quanto para a verificação do desempenho.

Na análise por fluido refrigerante, não foi verificada correlação significativa entre o desempenho dos módulos neurais e o fluido refrigerante utilizado pelos compressores ensaiados. As diferenças obtidas nesta análise estão ligadas ao fato de que a maior parte dos ensaios de baixa e média capacidade utilizam o fluido R-600a, enquanto a maior parte dos ensaios de alta capacidade utilizam o fluido R-134a.

O sistema neural, composto pelos três módulos neurais de capacidade, consumo e COP, foi treinado e testado para uma quantidade de ensaios não antes utilizada para verificação das ferramentas de redes neurais. Tal sistema foi projetado de forma a responder a ensaios de alta, média e baixa capacidade, assim como compressores com fluido R-600a e R-134a. Os resultados oriundos das análises dos conjuntos de teste indicam que o mesmo pode ser utilizado para toda esta gama de ensaios, mas com certas ressalvas. A primeira é relacionada a ensaios de baixa



capacidade. Caso seja necessário seguir os limites de diferença percentuais estipulados neste trabalho, não é recomendada a aplicação do sistema para tal faixa. A segunda ressalva é mais complicada, visto que só é possível identificar a mesma ao final do ensaio. Através dos resultados obtidos, foi verificado que o sistema é incapaz de apresentar resultados coerentes quando aplicado a um ensaio que apresente estabilização momentânea. Sendo assim, é recomendado um estudo a respeito deste efeito nos ensaios de desempenho de compressores herméticos.

Após uma revisão das atividades realizadas no desenvolvimento e teste das novas ferramentas, foi verificado o cumprimento de todos os objetivos propostos.

## 6.2 SUGESTÕES DE TRABALHOS FUTUROS

Ao longo do trabalho realizado foram surgindo novas ideias para o melhoramento do sistema neural. Enquanto algumas foram implementadas, outras acabaram não sendo utilizadas por inviabilidade de tempo ou decisão em conjunto com os orientadores. A seguir serão expostas propostas de alterações do sistema que podem levar a uma melhoria no desempenho do mesmo.

- Estudo sobre as atuais dinâmicas presentes nos ensaios de desempenho de compressores herméticos e investigação do motivo por trás de estabilizações momentâneas observadas durante os mesmos. Obtenção dos efeitos das condições iniciais de ensaio na dinâmica dos parâmetros de desempenho e estabelecimento de metodologia para padronizar tais dinâmicas.
- Treinamento de comitês de rede específicos para cada faixa de capacidade. O presente trabalho foi focado no desenvolvimento de um sistema capaz de realizar generalizações para uma grande faixa de compressores. No entanto, a criação de comitês específicos pode ser interessante para o melhoramento do desempenho das ferramentas baseadas em redes neurais.
- Explorar novas alternativas para a integração das respostas das redes nas ferramentas de inferência e prognóstico. Apesar dos bons resultados obtidos pelo sistema atual, estudos realizados durante a revisão bibliográfica indicaram alternativas para integração das respostas dos comitês que podem contribuir significativamente para o desempenho do mesmo. Vários estudos indicam a utilização de análise de componentes principais (PCA)

como um método bastante robusto para extrair respostas mais relevantes de comitês de redes neurais (AHMAD E ZHANG, 2002; AL-ALAWI, 2008; MERZ e PAZZANI, 1997; ZHANG, 1999).

- Inserção de novas entradas para a rede de prognóstico utilizando amostras do período de validação da inferência, conforme discutido na seção 5.4.

## REFERÊNCIAS

ABDELWAHED, M. S.; EL-BAZ, M. A.; EL-MIDANY, T. T. A proposed performance prediction approach for manufacturing using ANNs. World Academy of Science, **Engineering and Technology**, v. 6, p. 778-783. January 2012.

AL-ALAWI, S. M.; ABDUL-WAHAB, S. A.; BAKHEIT, C. S. Combining principal component regression and artificial neural networks for more accurate predictions of ground-level ozone. **Environmental Modelling & Software**, v. 23, p. 396-403. October 2007.

AHMAD, Z.; ZHANG, J. A comparison of different methods for combining multiple neural networks models. **Proceedings of the International Joint Conference on Neural Networks**, v. 1, 2002.

ASHRAE STANDARD. **ANSI/ASHRAE 23-2005**: Methods of testing for rating positive displacement refrigerant compressors and condensing units. Atlanta, EUA, 2005.

ASHRAE STANDARD. **ANSI/ASHRAE 41.9-2000**: Calorimeter test methods for mass flow measurements of volatile refrigerants. Atlanta, EUA, 2000.

AURÉLIO. Dicionário eletrônico do Aurélio, 2014.

BARBOSA, F. Q. **Redução das incertezas nas medições de grandezas elétricas em uma bancada de ensaios de desempenho de compressores**. Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

BIPM, IEC, IFCC, ILAC, ISSO, IUOAC, IUPAP, OIML. **JCGM 100**: Evaluation of measurement data – Guide to the expression of uncertainty in measurement. 2008. 134p.

CASELLA, A. V. **Ferramenta fuzzy-bayesiana para identificação do instante de entrada no regime permanente em ensaios de desempenho de compressores**. Florianópolis, 2008. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

ÇENGEL, Y. A.; BOLES, M. A. **Termodinâmica**. Quinta edição. McGraw-Hill, São Paulo, 2006. 740 p.

CORAL, R. **Método para Estimar a Capacidade de Refrigeração de Compressores Herméticos Integrável a Linha de Produção** Florianópolis, 2014. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

EDWARDS, P. J.; PEACOCK, A. M.; RENSHAW, D.; HANNAH, J. M.; MURRAY, A. F. Minimizing risk using prediction uncertainty in neural network estimation fusion and its application to papermaking. **IEEE Transactions on Neural Networks**, v. 13, i. 3, 2002.

EFRON, B.; TIBSHIRANI, R. **An introduction to the bootstrap**. Chapman & Hall, NY, 1993. 450 p.

ENGELBRECHT, A. P. **Computational Intelligence, An Introduction**. 2. ed, University of Pretoria, South Africa, 2007. 628 p.

ERTUNC, H. M.; HOSOZ, M. Artificial neural network analysis of a refrigeration system with an evaporative condenser. **Applied Thermal Engineering**, v. 26, i. 5-6, p. 627-635, 2006.

FLESCHE, R. C. C. **Desenvolvimento e Instalação de Recursos de Automação Aplicados a Ensaio de Compressores de Refrigeração da Embraco**. Florianópolis, 2006. Monografia (Curso de Engenharia de Controle e Automação Industrial), Universidade Federal de Santa Catarina.

FORTUNA, L.; GIANNONE, P.; GRAZIANI, S.; XIBILIA, M. G. Virtual instruments based on stacked neural networks to improve product quality monitoring in a refinery. **IEEE Transactions on Instrumentation and Measurement**, v. 56, i. 1, 2007.

GEMAN, S.; BIENENSTOCK, E.; DOURSAT, R. Neural networks and the bias/variance dilemma. **Neural Computation**, v. 4, 1992.

GHOBIAN, B.; RAHIMI, H.; NIKBAKHT, A. M.; NAJAFI, G.; YUSAF, T. F. Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network. **Renewable energy**, v. 34, i. 4, p. 976-982, 2009.

GRANITTO, P. M.; VERDES, P. F.; CECCATTO, H. A. Neural Networks Ensembles: Evaluation of Aggregation algorithms. **Artificial Intelligence**, v. 163, i. 2, p. 139-162, 2005.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v. 5, 1994.

HAYKINS, S. **Redes Neurais: Princípios e práticas**. Segunda Edição. Bookman, Porto Alegre, 2001. 900 p.

HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório**. Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

HU, Y. H.; HWANG, J. **Handbook of neural network signal processing**. CRC Press LLC, USA, 2002. 384 p.

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 917: Testing of refrigerant compressors**. 2. ed. Switzerland, 1989.

KRAMER, A. H.; SANGIOVANNI-VINCENTELLI, A. Efficient parallel learning algorithm for neural networks. **Advances in Neural Information Processing Systems**, v. 1, p. 40-48. 1989.

LIMA, L. C. A. **Controle da alimentação elétrica para a redução de tempo demandado por ensaios de desempenho de compressores e avaliação da influência da qualidade de energia elétrica nos resultados dos ensaios**. Florianópolis, 2010<sup>b</sup>. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

LIMA, V. R. **Desenvolvimento e avaliação de sistema neural para redução de tempo de ensaio de desempenho de compressores**. Florianópolis, 2010<sup>a</sup>. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

MATHWORKS. **Neural networks toolbox – user’s manual**. Versão 5, 2007.

MCCULLOCH, W.S., e PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, vol 5, p.115-133, 1943.

MENDEL J.M. e MCLAREN, R.W. Reinforcement-learning control and pattern recognition systems. **In Adaptive, Learning, and Pattern Recognition System: Theory and Application**, v. 1, p. 287-318. New York: Academic Press, 1970.

MERZ, C.; PAZZANI, M. Combining Neural Network Regression Estimates Using Principal Components. **Preliminary Papers of the 6th International Workshop on Artificial Intelligence and Statistics**, v. 1. 1997.

MOHANRAJ, M.; JAYARAJ, S.; MURALEEDHARAM, C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review. **Renewable and Sustainable Energy Reviews**. v. 16, p. 1340-1358, 2012.

NAFTALY, U.; INTRATOR, N.; HORN, D. Optimal ensemble averaging of neural networks. **Network: Comput. Neural Systems**, v. 8, p. 283-296, 1997.

PAPADOPOULOS, G.; EDWARDS, P. J.; MURRAY, A. F. Confidence estimation methods for neural networks: a practical comparison. **IEEE Transactions on Neural Networks**, v.12, i. 6, 2001.

PENZ, C. A. **Procedimentos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração**. Florianópolis, 2011. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

PETROVIC, S. A. B. **Proposta de arquitetura do sistema de automação aplicado a ensaios de desempenho de compressores herméticos de refrigeração**. Florianópolis, 2007. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

POLETTI, E. L. **Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos visando reduzir incertezas de medição**. Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. Second edition. Prentice Hall series in artificial intelligence, New Jersey, 2003. 1081 p.

SCUSSEL, J. N. **Proposta de ações para reduzir o tempo demandado por ensaio de desempenho de compressores herméticos.** Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

SILVEIRA, A. N. **Diminuição do tempo de transitório em ensaios de desempenho de compressores utilizando injeção de corrente contínua.** Florianópolis, 2010. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

SINGARAM, L. ANN prediction models for mechanical properties of AZ61 MG alloy fabricated by equal channel angular pressing. **International Journal of Research and Reviews in Applied Sciences**, v. 8, i. 3, p. 337-345, 2011.

STEINBACH, K. **Identificação do instante de entrada em condições de regime permanente em ensaios de desempenho de compressores.** Florianópolis, 2008. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

TRICHAKIS, I.; NIKOLOS, I.; KARATZAS, G. P. Comparison of bootstrap confidence intervals for an ANN model of a karstic aquifer response. **Hydrological Processes**, v. 25, i. 18, p.2827-2836, 2011.

WU, B.; YU, J. A neural network ensemble model for on-line monitoring of process mean and variance shifts in correlated processes. **Expert Systems with Applications**. v. 37, i. 6, p. 4058-4065, 2010.

YU, H.; WILAMOWSKI, B. M. “Levenberg–Marquardt Training” **Industrial Electronics Handbook**, vol. 5 – Intelligent Systems, 2<sup>nd</sup> Edition, chapter 12, p. 12-1 a 12-15, CRC Press, 2011.

YU, J. B.; XI, L. F. A. neural network ensemble-based model for online monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes. **Expert Systems with Applications**. v. 36, i. 1, p. 909-921, 2009.

ZHANG, J. Developing robust non-linear models through bootstrap aggregated neural networks. **Neurocomputing**, v. 25, Issue 1-3, p. 93-113. April 1999.

ZIO, E. A study of the bootstrap method for estimating the accuracy of artificial neural networks in predicting nuclear transient processes. **IEEE Transactions on Nuclear Sciences**, v.53, n. 3, 2006.